

**VŠB - Technická univerzita Ostrava**  
**Fakulta elektrotechniky a informatiky**  
**Katedra kybernetiky a biomedicínského inženýrství**

**Regionální segmentace biomedicínských obrazových dat -  
laboratorní úloha**

Regional Segmentation of Biomedical Image Data  
– Laboratory Task

VŠB - Technická univerzita Ostrava  
Fakulta elektrotechniky a informatiky  
Katedra kybernetiky a biomedicínského inženýrství

## Zadání diplomové práce

Student:

**Bc. Jan Bednář**

Studijní program:

N2649 Elektrotechnika

Studijní obor:

3901T009 Biomedicínské inženýrství

Téma:

Regionální segmentace biomedicínských obrazových dat  
- laboratorní úloha

Regional Segmentation of Biomedical Image Data – Laboratory Task

Jazyk vypracování:

čeština

Zásady pro vypracování:

1. Nastudování obecných principů zpracování digitálního obrazu.
2. Nastudování obecných principů segmentace obrazu.
3. Rešerše regionálních segmentačních metod pro zpracování obrazu.
4. Rešerše segmentačních metod pro modelování klinických obrazových dat.
5. Tvorba datové báze klinických obrazů pro testování segmentačních algoritmů.
6. Analýza konvenčních metod předzpracování obrazu v kontextu vybraných modelových klinických případů.
7. Design a realizace vybraných konvenčních metod regionální segmentace.
8. Design a realizace vybraných nekonvenčních metod regionální segmentace s prvky umělé inteligence.
9. Testování a kvantitativní evaluace segmentačních procedur pro analyzované klinické případy.
10. Návrh komplexního graficko-uživatelského rozhraní pro regionální segmentaci klinických obrazů.
11. Design exemplární laboratorní úlohy pro regionální segmentaci obrazových dat.
12. Zhodnocení dosažených výsledků.

Seznam doporučené odborné literatury:

- [1] EL-BAZ, Ayman S, Xiaoyi JIANG a Jasjit S SURI. *Biomedical image segmentation: advances and trends*. Boca Raton: CRC Press, Taylor & Francis Group, [2017]. ISBN 978-1482258554.
- [2] SURI, Jasjit S, David L WILSON a Swamy LAXMINARAYAN. *Handbook of biomedical image analysis*. New York: Kluwer Academic/Plenum Publishers, c2005. ISBN 978-0-306-48551-0.
- [3] BERRY, Elizabeth. *A practical approach to medical image processing*. New York: Taylor & Francis, c2008. ISBN 978-1584888246.


Formální náležitosti a rozsah diplomové práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.


Vedoucí diplomové práce: **Ing. Jan Kubiček, Ph.D.**

Datum zadání: 01.09.2018

Datum odevzdání: 30.04.2019



  
\_\_\_\_\_  
doc. Ing. Jiří Koziorek, Ph.D.  
*vedoucí katedry*

  
\_\_\_\_\_  
prof. Ing. Pavel Brandštetter, CSc.  
*děkan fakulty*

## Prohlášení

Prohlašuji, že jsem tuto diplomovou práci vypracoval samostatně. Uvedl jsem všechny literární prameny a publikace, ze kterých jsem čerpal.

V Ostravě 30.4.2019

A handwritten signature in blue ink, appearing to read 'Jan Bednář', written over a dotted line.

Bc. Jan Bednář



## **Poděkování**

Tímto bych rád poděkoval panu Ing. Janu Kubíčkovi, Ph.D. za trpělivost, věnovaný čas a drahocenné rady, které mi pomohly k úspěšnému vypracování této diplomové práce. V neposlední řadě tímto děkuji své rodině a přítelkyni za podporu při vypracovávání této práce.

## Abstrakt

V dnešní době, kdy dochází k významnému rozvoji výpočetních technologií a aplikace umělé inteligence do běžného života, je logickým krokem také zlepšování zdravotnických aplikací sloužící k detekci patologických tkání. Přesná detekce patologických útvarů hraje zásadní roli při plánování operačních zákroků a s tím spojeným pooperačním stavem. Proto je u segmentačních aplikací kladen důraz na přesnost. Tato diplomová práce se zabývá právě touto problematikou, konkrétně regionální segmentací. Podstatou této práce je komparativní analýza regionálních segmentačních metod na základě prahování. Jedná se o porovnání konvenční Otsu metody a nekonvenční soft metody na základě dekompozice pomocí fuzzy množin v kombinaci s lokální statistickou agregací. Výstupem této práce jsou analýzy segmentačních v závislosti na dynamickém efektu intenzity obrazového šumu. Pro účely analýzy byly vybrány snímky z CT a MRI. Druhým výstupem diplomové práce je software „Regionální segmentace 1.0.0“, která slouží k provedení segmentace a následnému objektivnímu vyhodnocení na základě evaluačních parametrů. Aplikace disponuje přehledným grafickým uživatelským prostředím, které bylo vytvořeno v prostředí MATLAB R2015a od firmy MathWorks. Třetím výstupem je laboratorní úloha na téma regionální segmentace, která bude sloužit pro výukové účely.

## Klíčová slova

Otsu segmentace, Fuzzy prahování, evaluační parametry, segmentace, analýza

## Abstract

Improving health applications for the detection of pathological tissues is also a logical step in today's world of computing technology and the application of artificial intelligence to everyday life. Accurate detection of pathological features plays an essential role in the planning of surgical procedures and the associated post-operative condition. Therefore, on segmentation applications the emphasis is laid on precision. This thesis deals with this issue, specifically regional segmentation. The essence of this work is a comparative analysis of regional segmentation methods based on thresholding. It is a comparison of conventional Otsu method and unconventional soft method based on fuzzy set decomposition in combination with local statistical aggregation. The output of this work are segmentation analyzes depending on the dynamic effect of image noise intensity. For analysis purposes, images from CT and MRI were selected. The second output of the thesis is software "Regional Segmentation 1.0.0", which is used to perform segmentation with subsequent evaluation. The application has a well-arranged graphical - user interface that was created in MATLAB R2015a by MathWorks. The third output is a laboratory task on the topic of regional segmentation, which will be used for educational purposes.

## Key words

Otsu segmentation, Fuzzy threshold, evaluation parameters, segmentation, analysis

## Obsah

Seznam použitých zkratk a symbolů .....	9
Seznam obrázků .....	10
Seznam tabulek .....	12
1 Úvod .....	13
2 Segmentace obrazu.....	14
2.1 Regionově orientovaná segmentace.....	14
2.1.1 Metoda slučování oblastí .....	14
2.1.2 Metoda narůstání oblastí .....	15
2.1.3 Metoda slučování a narůstání oblasti .....	15
2.2 Hranově orientovaná segmentace .....	17
2.2.1 Metody založené na první derivaci .....	17
2.2.2 Metody založené na druhé derivaci .....	18
2.2.3 Deformovatelné aktivní kontury .....	18
2.3 Statistické metody.....	19
2.3.1 Prahování.....	19
2.3.2 Otsu metoda.....	20
2.3.3 Shluková analýza .....	21
2.4 Hybridní metody.....	24
2.4.1 Watershed transformace .....	24
2.5 Znalostní metody.....	25
2.5.1 Metoda Active Appearance Model (AAM) .....	25
2.6 Neuronové sítě .....	25
2.6.1 Základní pojmy .....	26
2.6.2 Kohonenovy mapy.....	26
2.6.3 Algoritmus učení .....	27
3 Rešeršní studie .....	28
3.1 Watershed transformace .....	28
3.2 Prahování .....	28
3.3 Otsu metoda.....	29
3.4 Narůstání oblasti .....	29
3.5 K - means.....	30
4 Analýza regionální segmentace pro biomedicínská obrazová data .....	33
4.1 Obrazové databáze.....	33
4.2 Aplikace šumových generátorů .....	36
4.2.1 Gaussovský šum .....	36

4.2.2	Šum Sůl & Pepř .....	37
4.2.3	Šum Spekle .....	39
4.3	Předzpracování obrazu .....	40
4.3.1	Mediánová filtrace .....	40
4.4	Hodnotící parametry kvality obrazu .....	42
4.4.1	Střední kvadratická chyba .....	42
4.4.2	Špičkový poměr signál - šumu .....	43
4.4.3	Korelace .....	43
4.4.4	OTSU tvrdé prahování .....	43
4.5	Algoritmus implementace Otsu metody .....	46
4.5.1	Fuzzy měkké prahování .....	49
4.5.2	Testování soft prahování na reálných medicínských datech .....	52
5	Kvantitativní komparace a testování segmentačních metod .....	55
5.1	Analýza výpočetní náročnosti segmentačních metod .....	55
5.2	Výsledky provedené analýzy .....	55
5.2.1	Analýza vybraných výsledků segmentace .....	56
5.2.2	Celková analýza pro tři segmentační třídy .....	69
5.2.3	Celková analýza pro pět segmentačních tříd .....	70
5.2.4	Celková analýza pro deset segmentačních tříd .....	71
5.3	Vyhodnocení segmentace po aplikaci mediánové filtrace .....	73
6	Graficko-uživatelské rozhraní .....	74
7	Diskuse .....	79
8	Závěr .....	80
	Literatura .....	82
A	Seznam příloh .....	86

## Seznam použitých zkratk a symbolů

$\nabla$	Gradient
$\psi$	Směr gradientu
$\Sigma$	Suma
$\int$	Integrál
%	Procento
2D	„Dvourozměrný“ („dvoudimenzionální“)
3D	„Trojrozměrný“ („trojdimenzionální“)
CL	Competitive learning
COR	Korelace
dB	Decibel
GUI	Graficko – uživatelské rozhraní
MR	Magnetická rezonance
MSE	Střední kvadratická chyba
PCA	Analýza hlavních komponent
PSNR	Špičkový poměr signál - šumu
SOM	Samoorganizující se mapy

## Seznam obrázků

Obr. 1 Definice čtyř, osmi a šesti-okolí bodu.....	14
Obr. 2 Princip narůstání oblasti.....	15
Obr. 3 Princip segmentace slučování a dělení.....	16
Obr. 4 Detail skutečné hrany, profil jednoho řádku a 1. a 2. derivace.....	17
Obr. 5 Ukázka principu metody druhé derivace v porovnání s první derivací.....	18
Obr. 6 Princip metody Aktivní kontury .....	19
Obr. 7 Výsledek prahování.....	20
Obr. 8 Výsledky shlukování.....	21
Obr. 9 Rozdíl mezi klasickou a fuzzy množinou. ....	23
Obr. 10 Segmentace mozku pomocí Watershed a jeho výsledný 3D model segmentované tkáně. ....	24
Obr. 11 Princip zplavování obrazu.....	25
Obr. 12 Příklad jednoduché fyzické struktury Kohonenovy mapy. ....	26
Obr. 13 Metody prostorových prvků a narůstání oblasti.....	29
Obr. 14 Příklad principu narůstání oblasti. ....	30
Obr. 15 Aplikace K-means algoritmu na MR snímek mozku. ....	31
Obr. 16 Segmentace pomocí K-means algoritmu .....	32
Obr. 17 Ukázka snímku z databáze CT – cévy .....	34
Obr. 18 Ukázka snímku z databáze CT - játra .....	34
Obr. 19 Ukázka snímku z databáze MRI – cévy.....	35
Obr. 20 Ukázka snímku z databáze CT – chrupavky .....	35
Obr. 21 Ukázka aplikace Gaussovského šumu na obrazy z databáze CT – cévy.....	36
Obr. 22 Ukázka aplikace Gaussovského šumu na obrazy z databáze CT – játra.....	37
Obr. 23 Ukázka aplikace šumu Sůl & Pepř na obrazy z databáze MRI - chrupavky.....	38
Obr. 24 Ukázka aplikace šumu Sůl & Pepř na obrazy z databáze MRI - cévy .....	38
Obr. 25 Ukázka aplikace šumu Spekle na obrazy z databáze CT - cévy .....	39
Obr. 26 Ukázka aplikace šumu Spekle na obrazy z databáze MRI - cévy.....	40
Obr. 27 Ukázka aplikace mediánové filtrace na snímky chrupavky. Nahoře – aplikace masky [5 × 5]. Dole - aplikace masky [10 × 10] .....	41
Obr. 28 Ukázka aplikace mediánové filtrace na snímky z obrazové databáze CT - cévy. Nahoře – aplikace masky [5 × 5]. Dole – aplikace masky [10 × 10] .....	42
Obr. 29 Blokový diagram Otsu segmentační metody .....	43
Obr. 30 Histogram snímku – vlevo, původní snímek – vpravo .....	44
Obr. 31 Histogram pozadí pro Obr. 30. ....	44
Obr. 32 Histogram popředí pro Obr. 30 .....	44
Obr. 33 Výsledek segmentace pro rozdílně zvolený práh. Vlevo práh v hodnotě 2. Uprostřed původní obraz. Vpravo ideální práh v hodnotě 3. ....	45
Obr. 34 Ukázka Otsu segmentace s rozdílnou segmentační třídou, Šum Gaussovský, $\sigma^2=0.01$ .....	46
Obr. 35 Ukázka Otsu segmentace s rozdílnou segmentační třídou, Šum Sůl & Pepř, $d=0.1$ .....	47
Obr. 36 Ukázka Otsu segmentace s rozdílnou segmentační třídou, Šum Spekle, $\sigma^2=0.6$ .....	47
Obr. 37 Ukázka Otsu segmentace pro odlišné typy šumu, počet tříd = 3 .....	48
Obr. 38 Ukázka Otsu segmentace pro odlišné typy šumu, počet tříd = 5 .....	48
Obr. 39 Ukázka Otsu segmentace pro odlišné typy šumu, počet tříd = 10 .....	49
Obr. 40 Blokový diagram Fuzzy segmentační metody. ....	49
Obr. 41 Posloupnost trojúhelníkových funkcí členství .....	50
Obr. 42 Ukázka průměrové agregace. Vlevo - původní obrazová matice 3x3. Vpravo - výsledná matice po průměrové agregaci.....	51
Obr. 43 Ukázka průměrové agregace. Vlevo - původní obrazová matice 3x3. Vpravo - výsledná matice po mediánové agregaci.....	52
Obr. 44 Ukázka Fuzzy segmentace s průměrovou agregací a s rozdílnou segmentační třídou, šum Spekle, $\sigma^2 = 0.6$ .....	52

Obr. 45 Ukázka Fuzzy segmentace s průměrovou agregací a rozdílnou segmentační třídou, Šum Sůl & Pepř, $d=0.1$ .....	53
Obr. 46 Ukázka Fuzzy segmentace s mediánovou agregací a rozdílnou segmentační třídou, Šum Sůl & Pepř, $d=0.1$ .....	53
Obr. 47 Ukázka Fuzzy segmentace s průměrovou agregací a rozdílnou segmentační třídou, Šum Spekle, $\sigma^2 = 0.8$ .....	54
Obr. 48 Ukázka Fuzzy segmentace s mediánovou agregací a rozdílnou segmentační třídou, Šum Spekle, $\sigma^2 = 0.8$ .....	54
Obr. 49 Porovnání korelace mezi snímky CT a MRI, Otsu metoda se 3 segmenty, šum Gaussovský .	57
Obr. 50 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 3 segmenty, průměrová agregace, šum Gaussovský.....	59
Obr. 51 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 3 segmenty, mediánová agregace, šum Gaussovský.....	60
Obr. 52 Porovnání korelace mezi snímky CT a MRI, Otsu metoda se 3 segmenty, šum Sůl & Pepř...	62
Obr. 53 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 3 segmenty, průměrová agregace, šum Sůl & Pepř .....	62
Obr. 54 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 3 segmenty, průměrová agregace, šum Sůl & Pepř .....	64
Obr. 55 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 3 segmenty, mediánová agregace, šum Sůl & Pepř .....	65
Obr. 56 Porovnání korelace mezi snímky CT a MRI, Otsu metoda se 3 segmenty, šum Spekle .....	66
Obr. 57 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 5 segmentů, průměrová agregace, Gaussovský šum.....	67
Obr. 58 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 5 segmentů, mediánová agregace, šum Sůl & Pepř .....	68
Obr. 59 Vývoj trendu PSNR v závislosti na počtu segmentačních tříd – Otsu metoda .....	72
Obr. 60 Vývoj trendu PSNR v závislosti na počtu segmentačních tříd – Fuzzy metoda .....	72
Obr. 61 Blokový diagram GUI .....	74
Obr. 62 Use – case diagram .....	74
Obr. 63 Úvodní obrazovka segmentační aplikace .....	75
Obr. 64 Dialogové okno s možností výběru snímku .....	76
Obr. 65 Segmentační okno po aplikaci šumu .....	77
Obr. 66 Graficko - uživatelské rozhraní po provedení Otsu segmentace .....	78
Obr. 67 Graficko – uživatelské rozhraní po provedení Fuzzy segmentace .....	78

## Seznam tabulek

Tab. 1 Informační tabulka o segmentovaných biomedicínských obrazech.....	33
Tab. 2 Výpočetní náročnost segmentačních metod v závislosti na počtu segmentačních tříd a zvolené agregační metodě v případě Fuzzy metody .....	55
Tab. 3 Shrnutí výsledků Otsu segmentace pro 3 segmenty, Gaussovský šum.....	56
Tab. 4 Shrnutí výsledků Fuzzy segmentace pro 3 segmenty, průměrová agregace, Gaussovský šum .	58
Tab. 5 Shrnutí výsledků Fuzzy segmentace pro 3 segmenty, mediánová agregace, Gaussovský šum .	59
Tab. 6 Shrnutí výsledků Otsu segmentace pro 3 segmenty, šum Sůl & Pepř .....	60
Tab. 7 Shrnutí výsledků Fuzzy segmentace pro 3 segmenty, průměrová agregace, šum Sůl & Pepř...	63
Tab. 8 Shrnutí výsledků Fuzzy segmentace pro 3 segmenty, mediánová agregace, šum Sůl & Pepř...	64
Tab. 9 Shrnutí výsledků Otsu segmentace pro 5 segment, Gaussovský šum.....	65
Tab. 10 Shrnutí výsledků Fuzzy segmentace pro 5 segmentů, průměrová agregace, Gaussovský šum	67
Tab. 11 Shrnutí výsledků Fuzzy segmentace pro 5 segmentů, mediánová agregace, Gaussovský šum	68
Tab. 12 Průměrné hodnoty evaluačních parametrů pro MRI snímky, 3 segmentační třídy.....	69
Tab. 13 Průměrné hodnoty evaluačních parametrů pro CT snímky, 3 segmentační třídy .....	69
Tab. 14 Průměrné hodnoty evaluačních parametrů pro MRI snímky, 5 segmentačních tříd .....	70
Tab. 15 Průměrné hodnoty evaluačních parametrů pro CT snímky, 5 segmentačních tříd .....	70
Tab. 16 Průměrné hodnoty evaluačních parametrů pro MRI snímky, 10 segmentačních tříd .....	71
Tab. 17 Průměrné hodnoty evaluačních parametrů pro CT snímky, 10 segmentačních tříd .....	71
Tab. 18 Průměrné hodnoty evaluačních parametrů po aplikaci mediánové filtrace pro CT snímky. ...	73
Tab. 19 Průměrné hodnoty evaluačních parametrů po aplikaci mediánové filtrace pro MRI snímky..	73



# 1 Úvod

Výpočetní technika je díky pokroku v posledních letech stále více zapojována do medicíny a stává velice prospěšnou součástí pro mnoho oblasti zdravotnictví. Nedílnou součástí medicíny je samozřejmě diagnostika, která ulehčuje lékařům práci hlavně pomocí softwarových programů. Tato diplomová práce se zabývá hloubkovou analýzou dvou různorodých segmentačních procesů využívaných k diagnostice. Srovnávací analýze bude provedena na konvenční segmentační metodě – Otsu tvrdém prahování a nekonvenční segmentační metodě – Fuzzy měkkém prahování.

Cílem této práce je tedy kvantitativní porovnání a objektivní vyhodnocení účinnosti výše zmíněných segmentačních metod v kontextu dynamického efektu šumových generátorů. Druhým neméně důležitým výstupem je také software, který slouží k provedení segmentačních metod a výpočtu evaluačních parametrů.

V teoretické části je podrobně rozebrána problematika segmentace. Nejprve se problematika zaměřuje na přínosy a vysvětlení pojmu segmentace. Následně je problematika probírána z pohledu přístupů k segmentaci, kde je zařazena např. regionově orientovaná segmentace, nebo znalostní či hybridní metody. Rešeršní studie je zaměřena na nejnovější poznatky z oblasti výzkumu a vývoje segmentačních metod. Je zde rozebrána např. metoda Otsu, K-means, nebo hybridní metoda watershed.

V praktické části je provedena důkladná analýza účinnosti segmentace mezi Otsu tvrdým prahováním a Fuzzy měkkým prahováním. Dále je zde popsána manipulace s daty, mezi které patří aplikace šumových složek do obrazu, předzpracování pomocí mediánového filtru a také samotné aplikace segmentačních metod, včetně nastavení parametrů. Objektivizace vyhodnocení je dosažena pomocí evaluačních parametrů.

Součástí této diplomové práce je také vyvinutý software sloužící k aplikaci segmentačních metod a následnému vyhodnocení. V poslední kapitole je vytvořena laboratorní úloha, která bude sloužit studentům k pochopení regionální segmentace obecně a také k zjištění efektivity analyzovaných segmentačních metod na základě evaluačních parametrů.

## 2 Segmentace obrazu


Segmentace patří mezi jednu z nejdůležitější, ale také mezi jednu z nejsložitějších metod v cestě za analýzou obrazu, během níž může docházet ke ztrátám důležitých informací. Podstatou segmentačních metod je rozdělení obrazu do částí, které odpovídají daným objektům. Je-li výsledkem těchto operací je soubor regionů, které jsou závislé na objektech vstupního obrazu, se jedná o tzv. kompletní segmentaci, která využívá vyšší úrovně zpracování. Neodpovídají-li dané části objektům v původním obraze, jedná se o metodu částečnou. Ta je založena na principu homogenity obrazových vlastností, jako jsou např. jas či barva. [1][3]

Segmentace obrazu patří mezi nejpopulárnější proces ve zpracování medicínských snímků. Segmentační metody mají různé klasifikace - mohou být založeny na okrajích nebo regionech a proces může být manuální nebo plně automatizovaný. Zřejmě nejstarší metodou segmentace je manuální, která je jedna z nejjednodušších, ale zároveň nejnamáhavějších metod. V dnešní době se však od této metody díky rozvoji počítačové a výpočetní techniky alespoň částečně upouští a přenechávají se složitější operace právě na ni. Celou segmentaci však nahradit v mnoha případech nelze, obzvláště to platí v medicínských aplikacích. Je proto nezbytné, aby výsledky z poloautomatické, či automatické segmentace byly ověřeny člověkem – lékařem. Segmentační přístupy můžeme rozdělit do tří nejzákladnějších skupin podle dominantních rysů, kterých využívají. Můžou se zde zařadit parametrické segmentace, regionově orientované segmentace či segmentace založené na hranové reprezentaci.[2][8]

Tyto základní skupiny lze dále rozšířit do dalších skupin, které jsou vylepšeny použitím optimalizačních metod, případně vnášejí do procesu segmentace znalostní údaje. Mezi takto vylepšené metody patří znalostní, statistické a hybridní metody.[1]

### 2.1 Regionově orientovaná segmentace

Regionově orientované algoritmy segmentace jsou založeny na homogenitě oblastí, jejichž parametry je nutno definovat společnými parametry. Mezi tyto parametry patří například: textury, stupně úrovně šedi, tvar, barva apod. Výhodou tohoto druhu segmentace je vytváření segmentů a to má za následek, že nehledá v obraze vyšší složky frekvenčního pásma, což může značit hran v obraze, ale také šum. V zašuměných obrazech je použití této metody výhodnější.[8]



Obr. 1 Definice čtyř, osmi a šesti-okolí bodu [9]

Na Obr. 1 je naznačena množina složená z pixelu, přičemž středový bod je nazýván jako reprezentativní pixel nebo také reprezentativní bod, a okolní body jsou jeho sousedé ve vzdálenosti 1. [9]

#### 2.1.1 Metoda slučování oblastí

Princip slučování oblastí je jednoduchý. Na počátku slučovací metody segmentace jsou navoleny oblasti o malých velikostech, které jsou ideálně tvořeny samostatnými pixely. Je-li splněna

podmínka homogenity, dochází následně k porovnání dvou sousedních oblastí a jejich propojení. Způsob definice kritéria homogenity vychází z podobnosti vybraného parametru, na základě:

$$p_{i,m,n} \in \langle p_0 - \Delta p, p_0 + \Delta p \rangle, \quad (4.1)$$

kde  $p_0$ , resp.  $p_i$  jsou střední hodnoty parametru počáteční/ porovnávané oblasti a  $\Delta p$  je námi zvolená parametrová tolerance.


Pro dosažení kvalitnějších výsledků lze použít dynamický parametr podobnosti oblastí, které mají být spojeny. Dále lze také použít slučování síly hranic mezi oblastmi. To pracuje s místními rozdíly mezi pixely umístěných na obou stranách této vzniklé hrany. Síla tohoto hraničního přechodu je dána počtem pixelů  $N$  a silných hran  $N_s$ . Je-li hranice slabá, dojde k jejímu rozpadu, v opačném případě je hranice zachována. Na rovnici 4.2 je popsána slabá hranice.[10]

$$S_{i,j} = \frac{N_s}{N} \leq T \quad (4.2)$$

### 2.1.2 Metoda narůstání oblastí

Segmentace narůstání oblasti (z anglického „Region growing“) pracuje na principu seskupování sousedních pixelů, které mají podobnou hodnotu jasové složky. Na počátku jsou určeny počáteční body, tzv. semena, ze kterých se oblast (region) dále rozrůstá. Samotné přiřazování do nejbližšího okolí, viz Obr. 1 je provedeno na základě splnění určitých podmínek homogenity. Principiálně dochází k porovnání počátečního parametru a parametru daného pixelu. [10][11][12]

$$|p_s - p_i| \leq T \quad (4.3)$$




**Obr. 2 Princip narůstání oblastí. a) původní obraz, b) - d) představují mezikroky k finálnímu segmentovanému obrazu, který je vidět na pozici e). [11]**

Vztah 4.3 udává matematický aparát sloužící k porovnání daných parametrů, kde:  $p_s$  je referenční parametr počátečního bodu,  $p_i$  je parametr porovnávaného pixelu a  $T$  je rozhodovací úroveň pro zařazení daného bodu do regionu. Parametrem  $p$  bývá nejčastěji intenzita, popř. lokální průměr nebo odchylka. Pixely, které nesplňují kritérium 4.3, nejsou do oblasti zařazeny, a naopak. Takto je postupně procházen celý obraz až do doby, kdy do dané oblasti nelze přidat další bod. [10][11][12]

### 2.1.3 Metoda slučování a narůstání oblastí

Metoda slučování a narůstání oblastí (z anglického „Split and Merge“) vznikla jako spojení již výše zmíněných metod. Pomocí této metody dochází k postupnému dělení obrazu na stále menší a menší oblasti, a to v případě, že je původní obraz nehomogenní. Naopak sousední oblasti se zase spojují, splňují-li kritéria homogenity. Pře samotnou segmentací je nutné nadefinovat strukturu pro

správu oblastí, přičemž nejčastěji používanou strukturou je „Quart tree“<sup>1</sup> strukturu, jejíž princip lze vidět na Obr. 3. Při přechodu na další úroveň dochází k rozdělení na další čtyři oblasti, proto je tento krok také nazýván jako „čtvrtinové dělení“.[1][12][13][14]



**Obr. 3 Princip segmentace slučování a dělení. [13]**

Nezbytnou součástí této segmentační metody je již zmíněné kritérium homogenity, které je nutno nadefinovat. Toto kritérium hraje důležitou roli v chování algoritmu, neboť by měl brát v potaz druh obrázku, vlastnosti objektů v obraze apod. Například víme-li, že objekty v obraze jsou tmavé a naopak pozadí světlé, lze jako kritérium použít škálu šedi. Pro rozdělení oblastí lze použít stejné, ale i odlišné kritérium. Během fáze dělení oblastí lze porovnávat nově vzniklé oblasti, které mohou obsahovat pixely s obdobnými parametry a právě takto podobné oblasti je možné při splnění kritéria homogenity ihned sloučit a tím snížit množství nově vzniklých segmentů.[12][13][14]

### **Algoritmus slučování a narůstání oblastí**

1. Určení kritéria homogenity, určení stromové struktury.
2. Rozdělení oblastí, které nejsou homogenní a čtyři další podoblasti.
3. Spojení některých vzniklých segmentů do jednoho homogenního. Návrat k bodu 2.
4. Spojení sousedních regionů do jednoho, je-li to možné.
5. Je-li to nutné, odstranění nejmenších regionů tak, že dojde ke spojení s nejpodobnějším regionem.


[13]

<sup>1</sup> Stromová struktura

## 2.2 Hranově orientovaná segmentace

Většina algoritmů, které patří do této kategorie, vytváří předpoklad, že zainteresované struktury lze odlišit kvantifikovatelnými rysy, jako je intenzita obrazu nebo velikost gradientu. Základem těchto algoritmů jsou informace o hranách v obraze. Z těchto informací se poté určují samotné obrazové segmenty. Samotných metod sloužících k detekci hran v obraze je několik a všechny se liší přístupem k obrazu a hraně. Z toho lze také odvodit, že s odlišným přístupem docílíme i odlišného výsledku. Výsledkem těchto segmentací je však nový obraz, který se ve všech případech nazývá stejně, a to hranová mapa.[1][7][13][14]

Již z názvu této segmentační metody vyplývá, že významnou roli hrají hrany v obraze, přičemž hranou se rozumí místo v obraze, kde dochází k výrazné změně intenzity. Na Obr. 4 je zobrazen detail skutečné hrany spolu s horizontálním profilem hrany mezi dvěma oblastmi. Na obrázku jsou zachyceny také 1. a 2. derivace. První derivace je v místech s konstantním jasnem nulová a v místech přechodu kladná. Druhá derivace je v místech, kde funkce dosahuje minima (tmavá strana hrany) kladná. Záporná je v místech, kde funkce dosahuje maxima (světlá strana hrany), v místě přechodu je 2. derivace nulová.[6]



Obr. 4 Detail skutečné hrany, profil jednoho řádku a 1. a 2. derivace. [6]

### 2.2.1 Metody založené na první derivaci

Jak již bylo psáno výše, jedná se o metody založené na faktu, že v místě výskytu hrany dochází k největší změně intenzity a naopak v místech s konstantní intenzitou je první derivace rovna nule. Těmito metodám se též říká gradientní metody, přičemž gradient je vektorová veličina označená  $\nabla f(x,y)$ . Ta určuje směr největšího růstu funkce (směr gradientu) a strmost tohoto růstu. Vztah pro výpočet gradientu uvádí (4.4). Vztahy pro výpočet velikosti gradientu  $|\nabla f(x,y)|$  a jeho směru  $\psi$  jsou uvedeny níže (4.5) (4.6). [6][13]

$$\nabla f = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (4.4)$$


$$|\nabla f(x, y)| = \sqrt{\frac{\partial f^2}{\partial x} + \frac{\partial f^2}{\partial y}} \quad (4.5)$$

$$\psi(x, y) = \arg\left(\frac{\partial f}{\partial x}, \frac{\partial f}{\partial y}\right) \quad (4.6)$$

Gradientní operátory udávají strmost jasové funkce. Mezi nejznámější operátory patří Sobelův operátor, Prewittův operátor, Robertsův operátor a další. Jako nevýhody se jeví velká citlivost na šum a také chování u různých obrazových dat.[12]

### 2.2.2 Metody založené na druhé derivaci

Vystačíme-li si s informacemi o poloze hran a nepotřebuje-li nezbytně znát velikost hran a směr, lze využít metod využívajících druhé derivace. Tyto metody využívají faktu, že v místech s největší intenzitou prochází druhá derivace nulou. Principiálně je tento způsob jednodušší, než hledání maxim a minim v případě metod založených na první derivaci. Základní princip této metody v porovnání s výše zmíněnou metodou je uveden na Obr. 5. Na pozici a) je znázorněna skoková hrana, na pozici b) je vykreslena její první derivace a na pozici c) je její druhá derivace.[7][12][13]



**Obr. 5 Ukázka principu metody druhé derivace v porovnání s první derivací.[13]**


Klasickým příkladem operátoru využívajícího druhé derivace je Laplaceův operátor. Ten je odolný vůči rotaci, neboť má stejné vlastnosti ve všech směrech, ale nevýhodou může být vysoké vyhlazení (zkreslení) obrazu.

### 2.2.3 Deformovatelné aktivní kontury

Metody nazývané jako pružné či aktivní kontury mají za cíl najít hranice oblastí. Jedná se o algoritmy založené na detekci hran. Jejich využití je hlavně v oblasti výskytu specifického šumu, který při použití odlišných algoritmů způsobuje detekci neexistujících obrysů.[8][10]

#### 2.2.3.1 Aktivní kontury

Aktivní kontury (z anglického „snake“) jsou typické svým tvarováním kontur k hraně objektu v obraze. Tento proces se děje postupným „dohlazováním“, nikoliv skokově a to díky různým obrazovým silám, které se deformují a tím ovlivňují tvar výsledné kontury. Počáteční konturu je nutné inicializovat manuálně nebo na základě znalostí o tvaru a poloze objektů[1][10]



**Obr. 6 Princip metody Aktivní kontury [26]**

Na Obr. 6 je naznačen princip metody aktivních kontur. Je zde patrné rozšiřování oblasti a postupnému přibližování hranice k okraji oblasti zájmu.

### 2.2.3.2 Level-set

Řadí se do skupiny geometrických pružných kontur. Level-set algoritmy pracují na podobném principu jako aktivní kontury, ale s tím rozdílem, že k deformaci křivky dochází nepřímo pomocí level-set funkce. Ta každému bodu určuje jeho výšku nad nulovou hladinou. Tím vzniká povrch funkce, která se postupně adaptuje danému objektu. Metoda level-set dosahuje lepších výsledků než aktivní kontury a to hlavně u složitějších útvarů v obraze.[1][10]

## 2.3 Statistické metody


Statistické metody segmentace spočívají v klasifikaci pixelu či voxelu podle jeho intenzity. Nebere se ohled na to, kde leží v obraze, neuvažuje se tedy žádná prostorová informace. Jednou z nejjednodušších statistických metod segmentace je prahování (thresholding). Její podstatou je stanovení rozmezí intenzit tkání, daných dolní a horní prahovou intenzitou. Prahování patří díky relativně jednoduché implementaci a výpočtu mezi nejpoužívanější metody. V dnešní době má již několik modifikací a mezi jednu z nich nepochybně spadá také Otsu metoda, neboli Otsu prahování.[17][19][23]

### 2.3.1 Prahování

Prahování umožňuje potlačení takových oblastí, které nejsou pro další zpracování obrazu důležité. Principem metody je fakt, že objekty v obraze mají rozdílnou intenzitu jasu oproti jeho pozadí. Cílem je tedy stanovení hranice jasu - prahu, který oddělí významné objekty od pozadí. Výsledkem této metody je binární obraz, kdy 1 představuje prvky patřící do skupiny zájmových objektů a 0 pro další zpracování nevýznamné objekty (pozadí). Podle rovnice (4.7) je patrné, že u globálního prahování je nastaven pouze jeden práh pro celý obraz.

$$f(x,y) = \begin{cases} 1 & g(x,y) \geq T \\ 0 & g(x,y) < T \end{cases} \quad (4.7)$$

V dnešních aplikacích je však tento typ prahování takřka vyloučený a proto se přistupuje k víceúrovňovému prahování, kde je na celý obraz použito hned několik prahů.[12][19]



**Obr. 7 Výsledek prahování. a) původní obraz, b) obraz po prahování. [17]**

Na Obr. 7 lze vidět příklad segmentace obrazu pomocí prahování. Na pozici a je zobrazen původní snímek a na pozici b lze pozorovat výsledek prahovací metody. Existuje mnoho přístupů k prahování, avšak výsledek by měl být vždy totožný.

### 2.3.2 Otsu metoda

Metoda Otsu je typ globálního prahování, ve kterém závisí pouze monochromatické úrovni obrazu. Metoda Otsu, podle svého objevitele Nobuyuki Otsu vychází z klasického prahování a je široce používána, protože je v podstatě jednoduchá a účinná. Je založena na stanovení ideální úrovně prahu z histogramu snímku, a to výpočtem rozptylu. Prahová metoda Otsu zahrnuje iteraci podél všech pravděpodobných prahových hodnot a vyhodnocení standardního uspořádání pro všechny úrovně pixelů, které zaujímají obě strany prahu. Algoritmus předpokládá, že obraz zahrnuje histogram, který například obsahuje pixely v popředí i v pozadí (bimodální histogram) a dále hodnotí optimální práh, rozdělující popředí a pozadí tak, že jejich společné rozptylování je zanedbatelné.[20][21][22][23]

Nutností je definovat vnitřní rozptyl (within-class variance) a mezi rozptyl (intra class variance). Vnitřní rozptyl je dán vztahem (4.8).

$$\sigma_{\omega}^2(t) = \omega_0(t) * \sigma_0^2(t) + \omega_1(t) * \sigma_1(t)^2 \quad (4.8)$$

Výše zmíněné váhy  $\omega_0$  a  $\omega_1$  jsou pravděpodobnosti pozadí a popředí oddělených prahem  $t$  a  $\sigma_0$  a  $\sigma_1$  jsou odchylky těchto dvou tříd.

Vnitřní rozptyl je počítán pro každý práh. Prah s nejnižší hodnotou rozptylu je považován jako ideální prahovací úroveň daného obrazu. Tato operace je však výpočetně velmi náročná, protože je nutno nejdříve spočítat váhu a průměrnou intenzitu a až z ní vycházející rozptyl. Proto se častěji využívá mezi rozptylu. Ten je obdobně jako u vnitřního rozptylu počítán pro každý práh, ale ideální práh je určen jako nejvyšší hodnota rozptylu. Tento proces je méně náročný na výpočet, neboť není potřeba výpočtu rozptylu. Mezi-rozptyl je definován vztahem (4.9).

$$\sigma_b^2(t) = \omega_1(t) * \omega_2(t) * (\mu_1(t) - \mu_2(t))^2, \quad (4.9)$$

kde  $\omega_1$  je váha pozadí,  $\mu_1$  je průměrná hodnota intenzity pozadí,  $\omega_2$  je váha popředí a  $\mu_2$  je průměrná hodnota intenzity popředí




### 2.3.3 Shluková analýza

Mezi pokročilé prahovací metody lze zařadit také shlukovací analýzu (z anglického „clustering“), kterou lze považovat za prahování adaptivní. Úkolem shlukové analýzy je rozdělení bodů v obraze do několika klastrů<sup>2</sup> tak, že pixely ve stejných skupinách si jsou více podobné, než ve skupinách jiných. Jinak řečeno, pixel v dané skupině by se měl nejvíce blížit průměrné intenzitě popředí, potažmo pozadí. Velkou nevýhodou této metody je správné nastavení počátečních parametrů. Jejich úspěšnost je především v problematice takových objektů, které mají tendenci se přirozeně shlukovat.[25][27]

Obecně lze shlukování rozdělit na dvě podskupiny:

**Hard Clustering**<sup>3</sup>: Tento typ shlukování udává, že každý bod buď patří do klastrů jednoznačně, nebo ne. Každý bod je zařazen do některé z klastrů.

**Soft Clustering**<sup>4</sup>: Měkké shlukování namísto umístění každého datového bodu do samostatného klastru přiřazuje bodům míru pravděpodobnosti umístění v daném klastru. Příklad shlukování je uveden na Obr. 8. Je nutné si však uvědomit, že se jedná o ideální datový soubor, jehož body jsou jednoznačně oddělitelné. V praxi se setkáváme s mnohem složitějšími daty a my se pouze snažíme přiblížit k jednoznačné odlišitelnosti dat.



Obr. 8 Výsledky shlukování : a) Shluky bodů v dvourozměrné příznakové oblasti b) Správný počet shluků a správná klasifikace bodů c) Špatný počet shluků[27]

Jelikož úkol shlukování je subjektivní proces, existuje mnoho metod, které lze využít k dosažení tohoto cíle. Všechny dosud známé metody vychází z odlišného souboru pravidel pro definování "podobnosti" mezi datovými body. Ve skutečnosti existuje více než 100 algoritmů pro shlukování, ale v praxi se jich používá podstatně méně. Nejčastěji používané typy shlukování jsou uvedeny níže.[25]

- **Modely konektivity**: Principem této metody je fakt, že datové body blíže v datovém prostoru vykazují více vzájemné podobnosti než datové body ležící ve větší vzdálenosti. Tyto modely mají dva přístupy. V prvním přístupu začínají klasifikací všech datových bodů do jednotlivých clusterů a poté je shlukuje s poklesem vzdálenosti. Ve druhém přístupu jsou všechny datové body klasifikovány jako jediný cluster a poté rozděleny s tím, jak se vzdálenost zvyšuje. Příklady těchto modelů jsou algoritmus hierarchického klastrování.[25]

<sup>2</sup> Shluky

<sup>3</sup> Tvrdé prahování

<sup>4</sup> Měkké prahování

- **Těžišťové modely:** Jedná se o iterativní klastrovací algoritmy, ve kterých je pojem podobnosti odvozen blízkostí datového bodu k těžišti klastrů. K-means shlukování je populární algoritmus, který spadá do této kategorie. V těchto modelech se čísla klastrů požadovaných na konci musí být uvedeno v předstihu, což dává důležitost předběžné znalosti datového souboru.[25]
- **Distribuční modely:** Tyto modely shlukování jsou založeny na tom, jak je pravděpodobné, že všechny datové body v clusteru patří ke stejné distribuci. Tyto modely často trpí nadbytečností. Oblíbeným příkladem těchto modelů je algoritmus Maximalizace očekávání, který využívá vícerozměrné normální distribuce.[25]
- **Modely hustoty:** Tyto modely vyhledávají datový prostor pro oblasti s různou hustotou datových bodů v datovém prostoru. Izoluje různé oblasti hustoty a přiřazuje datové body v těchto oblastech ve stejném klastru. Oblíbenými příklady hustotních modelů jsou DBSCAN a OPTICS.[25]

Základním prvkem shlukovacích metod je metrika rozdílnosti příznakových vektorů, jinak řečeno vzdálenost bodů v prostoru příznaků. Pro tuto metriku platí:

$$D(\vec{x}, \vec{y}) \geq 0 \quad \forall \vec{x}, \forall \vec{y} \quad (4.10)$$

$$D(\vec{x}, \vec{y}) = D(\vec{y}, \vec{x}) \quad \forall \vec{x}, \forall \vec{y} \quad (4.11)$$

$$D(\vec{x}, \vec{x}) = 0 \quad \forall \vec{x} \quad (4.12)$$

Kde  $D(\vec{x}, \vec{y})$  představuje výslednou vzdálenost, a  $\vec{x}$  resp.  $\vec{y}$  značí příznakové vektory. Takových metrik existuje velmi mnoho, ale mezi základní patří matrica: Euklidova, Hellingerova, Normalizovaná Euklidova či Manhattan.

Euklidova metrika

$$D(\vec{x}, \vec{y}) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.13)$$

Manhattan


$$D(\vec{x}, \vec{y}) = \sum_{i=1}^n |x_i - y_i| \quad (4.14)$$

### 2.3.3.1 Metody shlukové analýzy

Níže jsou uvedeny dva představitelé těchto shlukovacích algoritmů, a to fuzzy c-means a K-means. Pojem fuzzy<sup>5</sup> pochází z angličtiny a přesně vystihuje i níže popsané algoritmy. Právě fuzzy algoritmy umí tyto nejasnosti zakomponovat do svých matematických procesů a dokážou je matematicky popsat. Důležitým pojmem ve fuzzy algoritmech je také fuzzy množina, která je jakýmsi rozšířením klasických množin. Ta funguje na principu přiřazení stupně příslušnosti každého bodu k dané množině.[28]

---

<sup>5</sup> Nejasný, neurčitý



**Obr. 9 Rozdíl mezi klasickou a fuzzy množinou. a) Klasická množina b) Fuzzy množina. [28]**

Na Obr. 9 lze pozorovat základní rozdíl mezi základní a fuzzy množinou. Na ose  $x$  jsou naznačeny hodnoty a osa  $\mu(x)$  naznačuje příslušnost daného prvku k množině. V klasické množině může prvek nabývat pouze hodnoty 0 nebo 1, kdežto ve fuzzy množině může prvek nabývat hodnot 0 až 1.

#### 2.3.3.1.1 Fuzzy c-means

Tento algoritmus patří do skupiny fuzzy algoritmů, které jsou založeny na měkkém shlukování, tedy že každý vstupní bod může patřit do více shluků najednou. Fuzzy c-Means je velmi často využíván k segmentaci obrazových dat. Nevýhodou však je, že před samotným procesem segmentace je potřeba znát přesný počet shlukovacích skupin, do kterých se následně budou data dělit.

Mějme  $N$  vstupních bodů označených jako  $x_i$ , kde  $i \in \langle 1, N \rangle$  a budeme je shlukovat do  $C$  shluků, které jsou pojmenovány  $c_j$ , kde  $j \in \langle 1, C \rangle$ , tak lze příslušnost daného bodu  $x_i$  do shluku  $c_j$  zapsat jako  $\mu_{i,j}$ . Tak vznikne matice  $U$  o rozměrech  $N \times C$ , která má dvě následující omezení.[27]

$$\mu_{i,j} \geq 0 \quad \forall j, j \in \langle 1, C \rangle; \quad \forall i, i \in \langle 1, N \rangle \quad (4.15)$$

$$\sum_{j=1}^C \mu_{i,j} = 1 \quad \forall j, j \in \langle 1, C \rangle \quad (4.16)$$

Algoritmus poté pracuje tak, že dojde k inicializaci shluků na náhodné vstupní body a následně dochází k výpočtu prvků matice příslušnosti. Z matice příslušnosti jsou poté vypočteny nové středy shluků. Tento průběh se následně opakuje až do chvíle, kdy je rozdíl mezi maticemi příslušnosti menší, než je požadovaná přesnost.[27]

#### Míra věrohodnosti

Jedna z nejsložitějších úloh shlukové analýzy je nalezení ideálního počtu shluků. Tato složitá úloha – fuzzyfikace - je měřitelná pomocí rozdělovacího koeficientu, který udává míru podobnosti fuzzy množin na pevné shluky v obraze. Pevným bodem se rozumí klasifikace bodu, který má největší podobnost. Samotný rozdělovací koeficient je vyjádřen vzorcem (4.16) a bývá též nazýván Dunnovým rozdělovacím koeficientem.[30]

$$F(U) = \frac{1}{N} \sum_{k=1}^c \sum_{i=1}^n m_{ik}^2 \quad (4.17)$$

### 2.3.3.1.2 K-means


Tento algoritmus, obdobně jako u fuzzy c-means, není schopen sám určit počet shluků, a proto musí být počet znám ještě před samotným spuštěním. Metoda K-means, dříve známá pod názvem MacQueenova metoda spočívá v klasifikaci objektů do konečného počtu shluků. Každý objekt je přiřazen shluku, k jehož středu má nejmenší vzdálenost. Z tohoto důvodu lze také metodu K-means často najít pod pojmem „metoda nejbližších středů“. Středů jednotlivých skupin shluků jsou označovány jako centroidy. Samotné zařazení objektů do odpovídajícího shluku je výsledkem metrik (např. Euklidovská či Manhattan vzdálenost) mezi objekty a centroidům. Poté následuje přepočítání středních hodnot v daných shlucích ze všech k nim přiřazených bodů. Proces klasifikace objektů a přepočítávání středních hodnot se opakuje. Cílem je dosažení co nejmenších rozdílů parametrů objektů uvnitř každého shluku podle [10] [29]

## 2.4 Hybridní metody

Jako hybridní metodu lze označit každou segmentační metodu, kterou nemůžeme jednoznačně zařadit mezi klasické, již výše zmíněné metody segmentace. Takové metody využívají různé přístupy klasických metod a často bývají mezi sebou kombinované.

### 2.4.1 Watershed<sup>6</sup> transformace


Hlavní myšlenkou této metody jsou geografické principy. Jak již samotný název metody napovídá, na původní obraz je nahlíženo jako na terén, který je postupně zakrýván vodou, a to z míst lokálních minim obrazu. V místech, kde by docházelo ke slívání vody, jsou vytvořeny hranice, tzv. hráze. Tyto hráze následně vytvářejí jednotlivé oblasti neboli regiony obrazu. Samotný proces končí po dosažení lokálního maxima obrazu. Na Obr. 10 je znázorněno využití watershed transformace v praxi při tvorbě 3D modelu mozku.[4] [5]



Obr. 10 Segmentace mozku pomocí Watershed a jeho výsledný 3D model segmentované tkáně.  
[4]

Princip zaplavování je znázorněn na Obr. 11. Je patrné, že aby nedošlo ke ztrátě informace při zaplavení všech vrcholů, přidává se na každý vrchol hráze, která představuje hranici mezi sousedními segmenty.

<sup>6</sup> Vodní předěl či vodní hráze



Obr. 11 Princip zplavování obrazu. [10]

## 2.5 Znalostní metody

Znalostní metody fungují na principu znalostí objektů, které byly získány již v minulosti a tyto znalosti jsou dány reprezentativními modely. Tyto modely jsou následně porovnávány s obrazem a cílem je najít shody mezi těmito daty. Jako reprezentativní modely jsou využívány modely z atlasu předloh a tento atlas je generován automaticky, nebo se mohou do něj informace vložit ručně, nicméně toto vkládání informací musí být prováděno po určité zkušenosti. Během použití tohoto algoritmu dochází k hledání podobností šablonami v atlasu a objekty v obraze. [1][12][31][32][33]

### 2.5.1 Metoda Active Appearance Model (AAM)

Jedná se o metodu, která zpracovává data pomocí PCA<sup>7</sup>, což je způsob identifikace vzorků v datech a vyjádření údajů tak, aby byly zvýrazněny jejich podobnosti a rozdíly. Hlavní výhodou PCA je, že jakmile jsou tyto vzorce nalezeny v datech a dojde ke kompresi dat, nedochází ke ztrátě informací. [32]

PCA se používá ke zjištění středního tvaru a hlavních změn tréninkových dat na průměrný tvar. Po nalezení modelu tvaru jsou všechny objekty s tréninkovými daty deformovány do hlavního tvaru a pixely převedeny na vektory. Model tvaru a vzhledu se kombinuje s PCA do jednoho modelu AAM. Přesunutím parametrů v tréninku s vědomostí lze vytvořit model, který poskytuje optimální parametry pro určitý rozdíl v intenzitě modelu a intenzitě normálního obrazu. [33]

## 2.6 Neuronové sítě

Neuronové sítě jsou inspirovány biologickými neuronovými sítěmi, a tedy jsou předurčeny mít schopnost chovat se stejně, nebo alespoň podobně jako neuronové sítě biologické. Nejedná se samozřejmě o vytvoření umělého lidského mozku, neboť je to velice složitě realizovatelná věc. Jedná se v podstatě o simulaci některých funkcí lidského myšlení a následnou aplikaci. [34]

Základním stavebním kamenem, jak již název napovídá je zjednodušeně řečeno nervová buňka – neuron. Jednotlivé neurony jsou mezi sebou propojeny hodnotícími vahami a takové spojení je následně schopno učit se na základě trénovacích vzorů. Lze tedy říci, že neuronové sítě jsou schopny si zapamatovat kombinaci různých postupů vedoucí k požadovanému cíli a tento postup následně aplikovat, potažmo vylepšovat, při aplikaci na nově přichozí data. [34]

<sup>7</sup> Analýza hlavních komponent


### 2.6.1 Základní pojmy

Neuronové sítě jsou velmi obsáhlé a dosti složité téma a proto je tato kapitola zaměřena na hlavní pojmy související s touto problematikou.

- Neuron – základní stavební jednotka neuronových sítí. Má jeden vstup a několik výstupů
- Synapse – spojení mezi jednotlivými neurony
- Váha – paměť hodnoty, která je představitelem algoritmu
- Vstup – synapse představují vstupy, které vstupují do neuronů s jednou váhou
- Vstupní vrstva – vstupní synapse, přes kterou vstupují zpracovávaná data do sítě
- Práh – hodnota, při které dochází k aktivaci výstupu neuronu
- Přenosové funkce – funkce, která upravuje výstup na dále se šířící hodnoty
- Výstup – každý výstup se zpracovává pomocí přenosové funkce, a výsledná hodnota je poskytována dalším částem neuronové sítě,
- Výstupní vrstva – výstupy ve výstupní vrstvě jsou zpracovány jako finální výstupy z modelu.
- Skrytá vrstva – vrstvy, které se nacházejí mezi vstupní a výstupní částí. Jsou v neuronové síti skryté
- Neuronová síť – rozložení všech neuronů ve vrstvách spojenými synapsemi
- Momentum – hybnost, koeficient udržující dynamiku učení algoritmu
- Bias – vychýlení, faktor nedovolující zůstat algoritmu v lokálních minimech, ale naopak jej ještě rozvětjuje

### 2.6.2 Kohonenovy mapy

Jedná se o neuronové síť typu SOM<sup>8</sup> a patří do skupiny samoučících sítí, tedy sítí učících se bez učitele. Nepotřebují tedy ideální vzory a k učení jim stačí jen velké množství signálů, které mají nějakou společnou vlastnost či naopak velké odlišnosti. [35]



Obr. 12 Příklad jednoduché fyzické struktury Kohonenovy mapy. [34]

Kohonenovy mapy využívají soutěžní strategii učení (CL<sup>9</sup>). Principem je, že výstupní neurony mezi sebou soutěží o to, který z nich bude aktivní a to má za následek shlukování neuronů podle právě aktivního neuronu. Jak je patrné z Obr. 12, každý vstupní neuron je propojen se všemi výstupními neurony a zde je důležitou součástí váha každé vazby. Váhový index vítězného, neboli aktivního neuronu totiž následně odpovídá číslu segmentu v obraze. Soutěžní strategie spočívá ve výpočtu vzdálenosti vah neuronu od vstupního neuronu. Neuron s nejnižším výstupem je považován za vítěze

<sup>8</sup> Samoorganizující se mapy

<sup>9</sup> Competitive learning – konkurenční učení

této soutěžní strategie a stává se aktivním. Vzdálenost těchto vektorů se počítá jakou Euklidovská vzdálenost.[31]

### **2.6.3 Algoritmus učení**

Postupně se prochází tréninková data a po detekci tréninkového vzoru k samotné soutěži mezi jednotlivými neurony. Jakmile dojde k vyhodnocení vítězného neuronu, dojde k úpravě váhových indexů všech neuronů, což má za následek posunutí váhových indexů tak, aby neurony ještě vylepšily svou pozici.

### 3 Rešeršní studie

Tato rešeršní práce je zaměřena na různé typy segmentačních metod používaných na medicínská data. V dnešní době existuje mnoho segmentačních metod, které slouží ke zpracování medicínských dat. Algoritmy lze rozdělit do mnoha podskupin, přičemž asi ty nejdůležitějšími jsou manuální, poloautomatické a automatické. Prozatím nejpoužívanější, ale zároveň časově nejnáročnějšími jsou segmentace manuální. Poloautomatické stále vyžadují manuální zásah člověka a to v podobě výběru počáteční akce. Automatické segmentační metody tento krok vypouští a nepotřebují žádný manuální zásah. V současnosti lze pozorovat snahu o vytlačení, nebo alespoň částečné nahrazení manuálních metod právě metodami automatickými, čemuž napomáhá také rozvoj výpočetní techniky. Je třeba mít ovšem na paměti, že jakýkoliv typ segmentace je nutné vždy zkontrolovat člověkem.

#### 3.1 Watershed transformace

V publikaci [4] uvádí GRAU, V., A.U.J. MEWES a spol. svou novou modifikaci watershed transformace, která významně zlepšuje proces této segmentace. V praktických aplikacích lze často pracovat s předběžnými informacemi o absolutní nebo relativní intenzitě měřeného objektů. Klasická watershed transformace ale neumožňuje zavedení těchto informací do výpočtu. Autoři tedy navrhnou využití souboru nižších funkcí, a to jednu pro každý objekt, který má být v obraze detekován. Samotné vylepšení je popsáno rovnicí 5.1,

$$LS_k(p) = \max_{q \in N_{G(p) \cup p}} \left( \frac{f_k(p, q)}{d(p, q)} \right) \quad (5.1)$$

, kde  $LS_k(p)$  je funkce, která kvantifikuje pravděpodobnost, že hrana bude mezi pixely  $p$  a  $q$ , vzhledem k tomu, že pixel  $p$  již dříve obdržel štítek  $k$ . S touto novou definicí může být např. jasný objekt segmentován z tmavšího pozadí, funkce  $f(k)$  může být vybrána tak, aby detekovala vysoký pokles hodnoty pixelů při průchodu zvenčí k vnějšímu objektu, a ne opak. Jiné podmínky založené na znalostech lze snadno zavést v závislosti na aplikaci. Aby bylo možné vypočítat funkce použité v (5.1), předpokládá se, že pixel  $p$  je znám ještě před pixelem  $q$ . Toho lze dosáhnout, pokud používáme regionální algoritmus pro výpočet vodního toku: označení štítků, tedy minimálních hodnoty po geodetické rekonstrukci, jsou známy na začátku procesu a postupně se rozšiřují na zbytek obrazu, po upřednostnění každého minima. [4]

#### 3.2 Prahování

Jedná se o jednu z nejstarších segmentačních metod a jedná se o jednoduchý, ale často účinný prostředek k získání segmentace v obrazech, kde různé struktury mají kontrastní intenzity nebo jiné kvantifikovatelné rysy. Segmentace se provádí seskupením všech pixelů intenzitou mezi dvěma prahovými hodnotami do jedné třídy. Při určování dobré prahové hodnoty se tato metoda spoléhá na to, že taková prahová hodnota může vést ke špatné segmentaci. Proces určující více než jednu prahovou hodnotu se nazývá multithresholding<sup>10</sup>. V pořadí operací zpracování obrazu se jako počáteční krok používá prahování. Prahové hodnoty v těchto algoritmech lze vybrat ručně podle a priori znalostí nebo automaticky prostřednictvím obrazových informací. Algoritmy mohou být dále rozděleny na okrajové, regionální a hybridní. Prahové hodnoty v algoritmech založených na okrajích se vztahují k informacím hran. Algoritmy se obecně snaží najít okrajové pixely a eliminovat vliv šumu. Jeho hlavní omezení spočívají v tom, že v nejjednodušší formě jsou generovány pouze dvě třídy a nelze je použít pro vícekanálové obrazy. Kromě toho prahové hodnoty obvykle nezohledňují prostorové charakteristiky obrazu. To způsobuje, že jsou citlivé na šum a intenzitu nehomogenity, které se mohou vyskytnout v magnetické rezonanci. Oba tyto artefakty v podstatě zkorumpují histogram obrazu, což dělá dělení obtížnější. Z těchto důvodů byly navrženy varianty klasické prahové


---

<sup>10</sup> Víceúrovňové prahování



hodnoty pro segmentaci lékařských obrazů, které zahrnují informace založené na lokálních intenzitách a konektivitě. [7] [36][38]

Na Obr. 13 lze pozorovat histogram skalárního obrazu, který má tři třídy odpovídající třem režimům. Práh určuje hodnotu, která odděluje požadované třídy. Segmentace se pak dosahuje seskupením všech pixelů s intenzitou větší než hodnota prahu do jedné třídy a všech ostatních pixelů do jiné třídy. Dvě potenciální prahové hodnoty jsou zobrazeny na Obr. 13 (a) v údolích histogramu. Stanovení více než prahové hodnoty je proces nazvaný multithresholding. [38]



**Obr. 13 Metody prostorových prvků a narůstání oblasti: (a) histogram zobrazující tři zřetelné třídy, (b) prostorový prostor 2D, (c) příklad růstu oblasti. [38]**

### 3.3 Otsu metoda

Klíčem této techniky je vybrat hodnoty hrany, jakmile se zvolí víceúrovňová jednotková plocha. Ta vychází ze stanovení úrovně prahu z histogramu snímku. Tato technika je používána k mechanickému provedení prahování založeného na tvaru sloupcového grafu, snížení obrazu šedé úrovně na binární obraz. Vychází se z faktu, že každý snímek obsahuje dvě kategorie pixelů a pomocí výpočtu dojde ke stanovení prahu tak, aby variace uvnitř této třídy byla nominální. Největší výhodou této techniky je jednoznačné oddělení různě intenzivních pixelů a proto se používají k separaci tmavých oblastí od světlých. Jelikož ale tento algoritmus zvažuje pouze intenzitu jednotlivých pixelů, nedokáže jednoznačně určit sousedství jednotlivých pixelů. [37]

Podle Bindu, C.H., Qiscet, [42] je základní algoritmus Otsu metody následující:

- 1) Získání hodnot histogramu ze vstupního obrazu
- 2) Nastavení počáteční hodnoty prahování
- 3) Provedení segmentace pomocí počáteční prahovací hodnoty, což má za následek vznik dvou skupin pixelů  $C_1$  a  $C_2$ .
- 4) Opakování bodu 2 pro získání nového prahu pro výše zmíněné skupiny pixelů

$$T = \frac{(T_{C_1} + T_{C_2})}{2}$$


- 5) Opakování kroku 2 až 4 do té doby, doku rozdíl mezi hodnotami  $T$  nebude mít tendenci blížit se k nule.

### 3.4 Narůstání oblasti

Tyto algoritmy jsou vhodné pro segmentaci objemových obrazů, které se skládají z velkých spojených homogenních oblastí. Obecně je lepší tuto techniku používat v zašuměných snímcích, kde je obtížné rozpoznat hrany. Region growing algoritmus je úspěšně používán při analýze lékařských

obrazů k segmentaci různých tkání, orgánů nebo lézí z MR obrazů. Například se používá v analýze MRI mozku pro segmentaci mozkových cév, segmentaci mozkových nádorů nebo extrakci povrchu z mozku. Jednoduchý přístup k segmentaci obrazu spočívá v tom, že se začíná od některých pixelů, které představují odlišné oblasti obrazu a následně dochází k rozšiřování, až do doby, kdy pokrývají celý obraz. Je potřeba dodržovat pravidlo popisující mechanismus nárůstu a pravidlo, které kontroluje homogenitu regionů po každém růstovém kroku. Autoři ELAYARAJA, P. a M. SUGANTHI [37] tyto pravidla popisují takto: [37][41]

- 1) Zvolení množiny pixelů, které mají určitý rozsah šedé úrovně
- 2) K nárůstu regionu dojde pouze podle pixelu, který má stejné vlastnosti, např. intenzita, či stupně šedi
- 3) Výše uvedený proces se opakuje, dokud již nelze regiony rozšiřovat.[37]



**Obr. 14** Příklad principu narůstání oblasti. [37]


Výhodou této metody pěstování v regionu je jednoduchá koncepce, kdy je zapotřebí pouze malý počet pixelů („semínek“). Pomocí této metody můžeme správně oddělit oblasti, které mají stejné vlastnosti a zároveň mají jasné okraje. Nevýhodou této metody je vysoká výpočetní náročnost a samotný výběr „semínek“ pro každou oblast, neboť při výběru špatných pixelů může dojít až ke sloučení regionů. [37][41]

### 3.5 K - means

K-means je technika, která má ve zvyku rozdělovat obraz do klastrů K. Je to algoritmické pravidlo které klasifikuje vstupní datové body do více kategorií. Algoritmické pravidlo předpokládá, že informační možnosti mají určitou plochu vektoru a snaží se v nich najít přirozenou aglomeraci klastrů. V tomto případě je vzdálenost, absolutní rozdíl mezi prvkem a středem klastru. Rozlišení je často podporováno barvou prvku, intenzitou, strukturou a umístěním nebo váženou kombinací těchto faktorů. Klasty jsou často označovány ručně, náhodně nebo heuristiky. Standard odpovědi závisí na počáteční množině klastrů, a tudíž hodnotě K. Algoritmus K-means shlukuje data iterativně výpočtem střední intenzity pro každou třídu a segmentování obrazu tím, že klasifikuje každý pixel ve třídě nejbližším průměrem. Obr. 15 ukazuje výsledek aplikace algoritmu K-means na řez mozku MR<sup>11</sup>


<sup>11</sup> Magnetická rezonance

snímku. Počet nastavených tříd byl v tomto případě roven třem, čemuž odpovídají, od nejtmaší po nejsvětleší mozkomíšní mok, šedá hmota a bílá hmota.[37][38]



**Obr. 15 Aplikace K-means algoritmu na MR snímek mozku. a) Původní snímek b) Segmentace K-means. [38]**

Podle P.S. GOH, W.L. NOWINSKI a spol. [39] je tento algoritmus vhodný pro segmentaci biomedicínských obrazů, neboť počet klastrů  $K$  je obvykle znám pro snímky jednotlivých oblastí. MR obraz hlavy se obecně skládá z oblastí představujících kost, měkké tkáně, tuky a pozadí. Z toho důvodu se vybírá číslo  $K$  jako 4. Počáteční centra clusterů jsou vybrána při prvním průchodu dat. Datová sada je rozdělena do klastrů  $K$  a datové body jsou náhodně přiřazeny do klastrů, což má za následek že klastry mají zhruba stejný počet datových bodů. Pro každý datový bod vypočteme euklidovskou vzdálenost od datového bodu k průměru každého klastru. Pokud není datový bod nejbližší k vlastnímu klastru, je nutné jej posunout do nejbližšího. Pokud je datový bod již nejbližší, k posunu nedojde. Proces pokračuje tak dlouho, dokud se prostředky klastrů nebudou posunovat více než je daná mezní hodnota, nebo než bude dosaženo limitu iterace. Příklad segmentace pomocí K-means algoritmu lze vidět na Obr. 16.[39]



**Obr. 16 Segmentace pomocí K-means algoritmu. a) původní MR snímek, b) výsledek segmentace. [39]**

Podle NAVEEN, A. a T. VELMURUGAN [40] lze princip algoritmu zjednodušeně popsat následujícími kroky:

- 1) Přiřazení čísla klastrů.
- 2) Náhodné vybrání středů klastrů
- 3) Výpočet střední hodnoty nebo středu klastru
- 4) Výpočet vzdálenosti mezi každým pixelem a každým středem klastru
- 5) Je-li vzdálenost blízká středu, dojde k přesunutí na tento klaster, v opačném případě dojde k přesunu na jiný
- 6) Přehodnocení středů klastrů.
- 7) Tento proces se opakuje, dokud nedojde k ustálení středů klastrů

## 4 Analýza regionální segmentace pro biomedicínská obrazová data

Po nastudování problematiky regionální segmentace bylo přistoupeno k aplikaci segmentačních metod. Vzhledem k tomu, že v praxi se lékaři snaží o co nejpřesnější a nejpreciznější lokalizaci různých patologických útvarů, dochází také ve vývoji segmentačních procedur. V dnešní době je mnoho přístupů k segmentaci obrazu, a proto jako stěžejní část této práce byla zvolena hloubková analýza dvou konvečně odlišných segmentačních aparátů. Na jedné straně konvenční metoda tvrdého prahování a na straně druhé nekonvenční Fuzzy měkké prahování.

V této práci je v první části řešeno umělé zašumění obrazových dat. Aby bylo možné vyhodnotit účinnost segmentačních procedur, je nezbytně nutné přidáním šumové složky data poškodit. Segmentace je aplikována jak na zašuměná data, tak také na nativních snímcích. Pomocí evaluačních parametrů jsou segmentovaná nativní data porovnávána se segmentovanými zašuměnými snímky a tím je zjištěna účinnost aplikované segmentace.

Vyhodnocování účinnosti segmentačních procedur je zajištěna pomocí evaluačních parametrů, kterými jsou střední kvadratická chyba, špičkový poměr signál – šum a korelace

Provedením výpočtů těchto vyhodnocovacích parametrů budou získány informace o účinnosti segmentačních procedur. Bude tak možné zjistit, která obrazová data jsou lépe segmentovatelná. Bude možné také zjistit, který z aplikovaných šumů má větší odolnost na segmentační procesy.

### 4.1 Obrazové databáze


Pro komparativní analýzu modelování tkáně na základě regionální segmentace byl nezbytně nutný pečlivý výběr biomedicínských dat. Pro tuto práci bylo vybráno několik databází. Jako stěžejní je výběr obrazů pocházející z dvou různých zobrazovacích systémů, a to ze systému magnetické rezonance a výpočetní tomografie.

**Tab. 1 Informační tabulka o segmentovaných biomedicínských obrazech**

<b>Obrazová databáze</b>	<b>Počet snímků</b>	<b>Rozlišení obrazu</b>
CT – cévy	20	628 × 628
CT – játra	20	630 × 630
MRI – cévy	20	640 × 640
MRI chrupavky	20	512 × 512


Vybrané datové soubory z magnetické rezonance poskytují informace o cévách a chrupavkách. Naproti tomu data z výpočetní tomografie pochází z vyšetření jater a cév. Náhled na analyzovaná data lze vidět na Obr. 17, Obr. 18, Obr. 19 a Obr. 20.

### Snímky cév - CT



Obr. 17 Ukázka snímku z databáze CT – cévy - Zdroj vlastní

### Snímky jater - CT




Obr. 18 Ukázka snímku z databáze CT - játra - Zdroj vlastní

### Snímky cév - MRI



Obr. 19 Ukázka snímku z databáze MRI – cévy - Zdroj vlastní

### Snímky chrupavek - MRI



Obr. 20 Ukázka snímku z databáze CT – chrupavky - Zdroj vlastní


## 4.2 Aplikace šumových generátorů

Pro důkladnou analýzu účinnosti segmentačních procedur bylo nutné aplikovat na vybraná data šumovou složku. Pro zašumění obrazů jsem zvolil 3 typy šumů, a to Gaussovský šum, šum Sůl & Pepř a šum Spekle. Každý šum byl aplikován na všechny snímky o třiceti kontinuálně se měnících parametrech.


### 4.2.1 Gaussovský šum

Gaussovský šum, též často nazývaný bílý šum je dán dvěma parametry, a to střední hodnotou  $\mu$  a rozptylem  $\sigma^2$ . Střední hodnota  $\mu$  je na všech snímcích konstantní o hodnotě  $\mu = 0.01$ . dynamicky měnící se složkou je při aplikacích rozptyl  $\sigma^2$ , přičemž počáteční hodnota  $\sigma^2_1 = 0.01$ ,  $\sigma^2_2 = 0.02$  a  $\sigma^2_{30} = 0.3$ .

Gaussovský šum,  $\sigma^2=0.01$     Gaussovský šum,  $\sigma^2=0.1$




Gaussovský šum,  $\sigma^2=0.2$     Gaussovský šum,  $\sigma^2=0.3$



Obr. 21 Ukázka aplikace Gaussovského šumu na obrazy z databáze CT – cévy - Zdroj vlastní

Na Obr. 21 a Obr. 22 Obr. 21 je zobrazena ukázka aplikace Gaussovského šumu na biomedicínská obrazová data.







**Obr. 22 Ukázka aplikace Gaussovského šumu na obrazy z databáze CT – játra - Zdroj vlastní**

#### **4.2.2 Šum Sůl & Pepř**

Tento šum, známější svým názvem z anglického jazyka „Salt & Pepper“ aplikuje do obrazu náhodně bílé a černé pixely – odtud název Sůl & Pepř. Matematicky je popsán parametrem hustoty  $d$ . Při aplikacích na snímky v této diplomové práci byla počáteční hodnota hustoty zvolena  $d_1 = 0.01$ ,  $d_2 = 0.02$  a  $d_3 = 0.3$ . Aplikace tohoto typu šumu lze vidět na Obr. 23 a Obr. 24.




Obr. 23 Ukázka aplikace šumu Sůl & Pepř na obrazy z databáze MRI - chrupavky - Zdroj vlastní




Obr. 24 Ukázka aplikace šumu Sůl & Pepř na obrazy z databáze MRI - cévy - Zdroj vlastní

### 4.2.3 Šum Spekle

Spekle šum je v obraze reprezentován světlými a tmavými body, které jsou důsledkem interferencí ultrazvukových vln rozptýlených z různých míst. Šum Spekle je matematicky popsán rozptylem  $\sigma^2$ . Pro aplikace je zvoleno třicet různých intenzit tohoto šumu, a to s počáteční hodnotou  $\sigma^2_1 = 0.04$ ,  $\sigma^2_2 = 0.08$  a  $\sigma^2_{30} = 1.2$ . Ukázkou aplikace tohoto šumu je zobrazena na Obr. 25 a Obr. 26.



Obr. 25 Ukázka aplikace šumu Spekle na obrazy z databáze CT - cévy - Zdroj vlastní



Obr. 26 Ukázka aplikace šumu Spekle na obrazy z databáze MRI - cévy - Zdroj vlastní

## 4.3 Předzpracování obrazu

Hlavním cílem předzpracování obrazu dosažení co největšího zvýraznění objektů zájmu oproti pozadí. Předzpracováním je tedy dosaženo zvýraznění přechodových oblastí – hran - objektů vůči pozadí a také zlepšení kontrastních vlastností obrazu.

### 4.3.1 Mediánová filtrace


Mediánová filtrace je nelineární proces, který je často používán k odstranění šumové složky y obrazu. Mediánový filtr je tedy využíván za účelem snížení šumu, ale zároveň zachovává hrany objektů v obraze.

Pro účel filtrace biomedicínských snímků mediánová filtrace Jedná se o filtr určený pro matice 2D obrazu. Pro analýzu biomedicínských dat byly použity 2 velikosti mediánového filtru, a to  $[5 \times 5]$  a  $[10 \times 10]$ .


Mediánový filtr je nízkofrekvenční filtr, který odstraňuje vysokofrekvenční složky z obrazu. Samotná filtrace funguje na principu diskretní 2D konvoluce. Výsledkem filtrace pomocí mediánového operátoru je vyhlazení kontur objektů. Nejčastěji je používán k odstranění šumu Sůl & Pepř. Jeho algoritmus nejprve seřadí všechny hodnoty z aktuální konvoluční matice a vybere hodnotu ležící uprostřed. Tou se pak nahradí zpracovávaný bod v obraze. V závislosti na hustotě šumu, může být efektivnější aplikace mediánového filtru na větší okolí bodu. Tzn. aplikace konvoluční matice o

větších rozměrech než je základní. Výpočet mediánu z většího okolí bodu však může mít za následek ztrátu detailu a výraznější rozmazání obrazu, tzv. posterizaci.[45]

Jeho aplikace a výsledky je možné pozorovat na Obr. 27 a Obr. 28.



Obr. 27 Ukázka aplikace mediánové filtrace na snímky chrupavky. Nahoře – aplikace masky [5 ×5]. Dole - aplikace masky [10 ×10] - Zdroj vlastní



Obr. 28 Ukázka aplikace mediánové filtrace na snímky z obrazové databáze CT - cévy. Nahoře – aplikace masky [5 × 5]. Dole – aplikace masky [10 × 10] - Zdroj vlastní

## 4.4 Hodnotící parametry kvality obrazu

V dnešní době existuje mnoho objektivních metod, které slouží k hodnocení kvality segmentace. V této práci jsou aplikovány evaluační parametry, podle kterých je možné objektivně vyhodnotit kvalitu segmentace.

### 4.4.1 Střední kvadratická chyba

Parametr  $MSE^{12}$  je jeden z nejjednodušších parametrů hodnocení kvality. MSE zjišťuje střední kvadratickou chybu mezi nativním a šumem znehodnoceným snímkem. Rovnice 7.1 udává výpočet MSE.

$$MSE = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N (x_{i,j} - y_{i,j})^2, \quad (7.1)$$

kde  $M$  znamená velikost obrazu na horizontální ose a  $N$  představuje velikost obrazu na vertikální ose.  $X_{i,j}$  značí pixel segmentovaného snímku na pozicích  $i$  a  $j$ . Parametr  $Y_{i,j}$  představuje pixel z původního snímku na souřadnicích  $i, j$ . [47]

<sup>12</sup> Mean squared error

U parametru MSE platí, že čím nižší výsledná hodnota, tím kvalitněji byla segmentace provedena.

#### 4.4.2 Špičkový poměr signál - šum

Parametr  $PSNR^{13}$  značí poměr mezi maximálním výkonem užitečného a neužitečného signálu. Jako neužitečný signál lze v mém případě označit šumem znehodnocený snímek. Výpočet PSNR vychází z MSE je popsán níže uvedeným vzorcem:

$$PSNR_{dB} = 10 \log_{10} \left( \frac{m^2}{MSE} \right), \quad (7.2)$$

kde  $m$  udává maximální hodnoty, kterých může pixel v obrázku nabývat (0 – 255). Jednotkou je decibel ( $dB$ ). Je-li obraz po filtraci kvalitní, měla by jeho hodnota  $PSNR$  dosahovat co nejvyšších hodnot, ideálně se blížit hranici 50dB. [46][47]

#### 4.4.3 Korelace

Pearsonův korelační koeficient  $r$  je parametr lineární korelaci dvou proměnných, v tomto případě medicínských snímků. Jeho výpočet je dán poměrem kovariance proměnných, které jsou vynásobeny jejich směrodatnými odchylkami. Matematický popis předpisem: [48]


$$r = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (Y_i - \bar{Y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \cdot \sqrt{\sum_{i=1}^n (Y_i - \bar{Y})^2}} \quad (7.3)$$

Jedná se o bezrozměrnou veličinu. Čím vyšší hodnota korelace, tím kvalitněji byla segmentace provedena. Meze korelace jsou dány od 0 do 1, přičemž 1 představuje úplnou podobnost. Tuto veličinu po přenásobení 100 lze také udávat v %.

#### 4.4.4 OTSU tvrdé prahování

Jak je již uvedeno v podkapitolách 2.3.2 a 3.3, Otsu metoda je metoda tvrdého prahování a hlavní nevýhodou metod založených na tomto typu prahování je fakt, že pixely, které disponují stejnou úrovní jasu jsou vždy segmentovány do stejné segmentační třídy. Otsu metoda totiž přiřazuje pixelům příslušnost k dané množině buď hodnotu 0 nebo 1, tedy zda jednoznačně patří do dané množiny, či nikoliv.


Otsu metoda je založena na určení ideálního prahu pro vybraný snímek. Tento práh je získáván pomocí hodnoty vnitřního rozptylu, nebo pomocí hodnoty mezi-rozptylu. Vnitřní rozptyl je hodnota uvnitř jednoho segmentu a jako ideální práh je nastavena nejnižší hodnota tohoto rozptylu. Naopak při výpočtu mezi-rozptylu je jako nejideálnější práh nastaven tam, kde odstín šedi dosahuje nejvyšší hodnoty.



Obr. 29 Blokový diagram Otsu segmentační metody – Zdroj vlastní


<sup>13</sup> Peak signal to noise ratio

Pro ilustraci a názorné pochopení principu výpočtu a stanovení nejideálnějšího prahu je uveden ilustrativní příklad. Je dán zkušební snímek. V tomto případě snímek o velikosti 6x6 pixelů s šesti různými odstíny šedi v něm obsažených. Pro názorné předvedení principu výpočtu a pochopení je na Obr. 30 zobrazen příklad výpočtu ideálního prahu. Obrázek reprezentuje 6 x 6 pixelů, jejichž hodnoty mohou nabývat 6 různých hodnot (0 až 5). Na Obr. 30 vlevo je vykreslen histogramu snímku, který je zobrazen na Obr. 30 vpravo. Na ose x je rozložení odstínů šedi a na ose y četnost výskytu jednotlivých pixelů v daných intenzitách.



**Obr. 30 Histogram snímku – vlevo, původní snímek – vpravo [43]**


Vzhledem k tomu, že celkový počet odstínů šedi je 6, je mezi-rozptyl počítán právě šestkrát, ale pro ilustraci je níže popsána metoda výpočtu pro práh, který je reprezentován číslem 2. Obecný princip výpočtu mezi-rozptylu uvádí (4.9), nejprve jsou vypočteny váhy pro pozadí a následně pro popředí snímku.



$$\omega_1(2) = \frac{8 + 7}{36} = 0.4166$$

$$\mu_1(2) = \frac{(0 \times 8) + (1 \times 7)}{15} = 0.4667$$

**Obr. 31 Histogram pozadí pro Obr. 30. [43]**



$$\omega_2(2) = \frac{2 + 6 + 9 + 4}{36} = 0.5833$$

$$\mu_2(2) = \frac{(2 \times 2) + (3 \times 6) + (4 \times 9) + (5 \times 4)}{21} = 3.7143$$

**Obr. 32 Histogram popředí pro Obr. 30[43]**



Nyní, když jsou známy všechny proměnné potřebné k výpočtu mezi-rozptylu, dosadíme do (4.9).


$$\sigma_b^2 = \omega_1 * \omega_2 * (\mu_1 - \mu_2)^2$$

$$\sigma_b^2 = 0.4166 * 0.5833 * (0.4667 - 3.7143)^2$$

$$\sigma_b^2 = \mathbf{2.5629}$$

Z tohoto postupu je patrné, že pro hodnotu pixelu 2 je mezi-rozptyl roven 2.5629. Tímto způsobem je dále počítán mezi-rozptyl pro všechny pixely v obraze. Tímto bychom došli k závěru, že nejvyšší hodnota mezi-rozptylu je dosažena pro pixel s hodnotou 3, a tudíž právě tam leží nejideálnější práh pro daný obraz.

Z Obr. 33 je patrný rozdíl mezi zvoleným prahem. Vpravo je výsledná segmentace po zvolení ideálního prahu v hodnotě 3. Vlevo je výsledná segmentace po zvolení prahu s hodnotou 2.




**Obr. 33 Výsledek segmentace pro rozdílně zvolený práh. Vlevo práh v hodnotě 2. Uprostřed původní obraz. Vpravo ideální práh v hodnotě 3. [43]**

## 4.5 Algoritmus implementace Otsu metody

V této kapitole bude rozebrána multiregionální Otsu segmentace v prostředí MATLAB. Tato funkce je použita k provedení analýzy a zjištění účinnosti Otsu segmentační metody


Algoritmus metody Otsu je následující:

1. Načtení snímku
2. Výpočet histogramu vybraného snímku
3. Výpočet váhy a průměrné intenzity popředí a pozadí
4. Výpočet mez – rozptylu
5. Nalezení ideálních prahů pro zvolený počet oblastí
6. Segmentace daného snímku
7. Zobrazení segmentovaného snímku




**Obr. 34 Ukázka Otsu segmentace s rozdílnou segmentační třídou, Šum Gaussovský,  $\sigma^2=0.01$  - Zdroj vlastní**

Pro zjištění nejideálnější a nejpřesnější segmentace byly porovnávány různé počty segmentačních oblastí, a to 3, 5 a 10. V každé ze zvolených segmentačních oblastí bude mezi-rozptyl počítán 256krát. Na Obr. 34 zobrazen výsledek segmentace pro jeden snímek a výše zmíněný počet segmentačních úrovní. Na následujících obrázcích jsou zobrazeny výsledky Otsu segmentace pro různé obrazové databáze a různé šumy. Obr. 35 vykresluje výsledek po Otsu segmentaci na MRI snímcích chrupavky se šumem Sůl & Pepř, Obr. 36 naopak výsledek Otsu segmentace na CT snímcích jater se šumem Spekle. Na Obr. 37 lze vidět Otsu segmentaci se třemi segmentačními třídami a odlišnou šumovou složkou.




Obr. 35 Ukázka Otsu segmentace s rozdílnou segmentační třídou, Šum Sůl & Pepř,  $d=0.1$  - Zdroj vlastní




Obr. 36 Ukázka Otsu segmentace s rozdílnou segmentační třídou, Šum Spekle,  $\sigma^2=0.6$  - Zdroj vlastní






Obr. 37 Ukázka Otsu segmentace pro odlišné typy šumu, počet tříd = 3 - Zdroj vlastní



Obr. 38 Ukázka Otsu segmentace pro odlišné typy šumu, počet tříd = 5 - Zdroj vlastní




Obr. 39 Ukázka Otsu segmentace pro odlišné typy šumu, počet tříd = 10 - Zdroj vlastní

#### 4.5.1 Fuzzy měkké prahování

Fuzzy měkké prahování je alternativním řešením Otsu metody. Metody založené na tvrdém prahování neberou v potaz špatnou klasifikaci dat, které mohou být způsobeny např. šumem zaneseným obrazem či nerovnoměrným osvětlením atp. Tento fakt lze ovlivnit zanesením prostorové informace do výpočtů, což umožňuje tato Fuzzy metoda.

Tato segmentační prahovací metoda přiřazuje stupeň členství každému pixelu pro každou segmentační třídu. Takto vzniklý stupeň členství každého pixelu je poté pomocí prostorové informace modifikován na nový stupeň členství. Fuzzy segmentační metoda pracuje ve dvou krocích, které jsou popsány níže.




Obr. 40 Blokový diagram Fuzzy segmentační metody. Zdroj vlastní



Hlavní rozdíl mezi Fuzzy a Otsu metodami je tedy ten, že Fuzzy prahování udává každému pixelu jistou míru příslušnosti pro každý region, kdežto Otsu metoda je pouze schopna určit, zda pixel do daného segmentu zcela patří nebo zcela nepatří.

#### 4.5.1.1 Jasová klasifikace

Metoda využívá faktu, že každý pixel je popsán tzv. příznakovým vektorem. Ten se skládá z fuzzy hodnot daného pixelu pro každou klasifikační třídu. Jednoduše řečeno, chceme-li multiregionální model, který je sestaven ze šesti oblastí, poté každý pixel bude popsán šesti funkcemi příslušnosti. Pro ukázkou jsou na Obr. 41 zobrazeny trojúhelníkové funkce, které popisují funkci členství. V tomto případě se jedná o model, který generuje 4 segmentační třídy, jenž jsou určeny vlastními vrcholy  $V_1 - V_4$ .



Obr. 41 Posloupnost trojúhelníkových funkcí členství [44]

Pro trojúhelníkové funkce platí:

$$\max(\mu_1(x)) = 1 \quad (7.1)$$

$$\mu_1(x_0) = \mu_{l+1}(x_0) = 0.5 \quad (7.2)$$

Tato část segmentace využívá hybridního přístupu k nalezení centroidů na základě metody K-means. Metoda K-means spadá do shlukové analýzy a data klasifikují do klastrů podle Euklidovské vzdálenosti od daného těžiště. Z této metody jsou následně využívána pouze těžiště, které se následně využívají pro aplikaci fuzzy členských funkcí. Algoritmus K-means pracuje na principu iterativního hledání hodnot vektorů tím, že snižuje střední odchylku mezi pixely a vektory, které mají k těmto datům nejmenší euklidovskou vzdálenost. Nakonec je rozděluje do daného počtu klastrů.

Základní princip je popsán ve dvou následujících krocích:

1. **Klasifikace** - Všechny pixely jsou přiřazeny do tříd, které jsou určeny vektory  $\mu_i$  na základě nejmenší euklidovské vzdálenosti. Přiřazování se následně řídí vztahem:

$$y_i = \arg \min_i ||x_i - \mu_i|| \quad (7.3)$$

2. **Přepočítání vektorů** – Dojde k výpočtu nových hodnot  $\mu_i$ , a to pomocí střední hodnoty pixelů  $x_i$ , které byly zařazeny do třídy předepsané vektorem  $\mu_i$ . Výpočet je následující:

$$\mu_i = \frac{1}{l_j} \sum_{i=1, y_i=j}^l (x_i) \quad (7.4)$$

kde  $l_j$  je počet pixelů, který byly klasifikovány do dané třídy. Vrchol každé třídy je dán jako pixel s maximální četností.[44]

## Prostorová agregace

Jedná se o prostorovou agregaci pixelů na základě zvážení informace okolí pixelu. Agregace může modifikovat funkci příslušnosti pixelu na základě zvážení informace z okolí. Hlavním nástrojem této agregace jsou operátory, které lze definovat jako matematickou funkci, která přiřazuje jakémukoli číslu reálné číslo. Obecnou agregační funkci lze zapsat takto:

$$x = \text{agg}(x_1, x_2, x_3, \dots, x_n) \quad (7.5)$$

## Průměrová agregace


Tento agregát provádí průměrování každé členské funkce na základě následující vztahu,

$$\mu_l^2(l(r)) = \sum_{r_i \in \eta(r)} \omega_i * \mu_l(l(r_i)), \quad (7.6)$$

kde  $\omega_i$  jsou váhy pixelů a musí platit:

$$\omega_i = 1/|\eta(r)|, \quad (7.7)$$

kde  $|\eta(r)|$  je modul sousedství. Na Obr. 42 je znázorněn postup prostorové agregace. V levé části obrázku je původní snímek, reprezentován maticí 3x3 pixelů. Červeně je znázorněn středový pixel, jehož hodnota je výrazně odlišná od svého okolí a je zde silný předpoklad šumového pixelu. V pravé části obrázku je výsledek aplikace průměrového agregátu.



**Obr. 42 Ukázka průměrové agregace. Vlevo - původní obrazová matice 3x3. Vpravo - výsledná matice po průměrové agregaci. Zdroj vlastní.**

## Mediánová agregace


Členství každého pixelu  $\eta(r)$  je agregováno mediánovým agregátem, který je dán matematickým předpisem:

$$\mu_l^2(l(r)) = \text{median}_{s \in \eta(r)} \{\mu(l(s))\} \quad (7.8)$$

Medián reprezentuje prostřední hodnotu v případě, kdy jsou všechny prvky matice seřazeny vzestupně.  $x_1 \leq x_2 \leq x_3 \leq x_4 \leq \dots \leq x_n$ . Pokud má takto vzniklá posloupnost čísel lichý počet, nelze prostřední hodnotu jednoznačně určit, a proto je vypočítána z dvou středových hodnot dle vztahu:


$$\text{median} = \frac{\frac{x_n}{2} + \frac{x_{n+1}}{2}}{2} \quad (7.9)$$

Lokální agregace je aplikována jako čtvercová matice o rozměrech  $n \times n$  a je iteračně aplikována na obrazová data. Jednotlivé části obrazu jsou přenásobeny výše zmíněnou maticí – konvolučním jádrem, a postupným posouváním je počítána hodnota pro středový pixel čtvercové matice. Ukázka mediánové agregace je znázorněna na Obr. 43.



Obr. 43 Ukázka průměrové agregace. Vlevo - původní obrazová matice 3x3. Vpravo - výsledná matice po mediánové agregaci. Zdroj vlastní.

#### 4.5.2 Testování soft prahování na reálných medicínských datech



Obr. 44 Ukázka Fuzzy segmentace s průměrovou agregací a s rozdílnou segmentační třídou, šum Spekle,  $\sigma^2 = 0.6$  - Zdroj vlastní


Stejně jako u Otsu metody, i zde byl nastaven stejný počet segmentačních tříd a opět zde probíhal výpočet evaluačních parametrů za účelem zjištění účinnosti segmentace. Nutno podotknout, že výpočetní náročnost soft prahování je podstatně vyšší, než u Otsu metody. Z tohoto důvodu došlo ke snížení počtu segmentovaných dat. Fuzzy prahovací segmentační metoda je aplikována na osmi snímcích z každé obrazové databáze, přičemž na každý snímek je aplikován šum o deseti různých intenzitách.

Algoritmus *Fuzzy* segmentace je následující:


1. Načtení snímku
2. Nastavení počtu segmentačních úrovní
3. Definice těžiště tříd
4. Definice Fuzzy členství
5. Výběr a aplikace lokální agregace




6. Segmentace daného snímku
7. Zobrazení segmentovaného snímku




**Obr. 45 Ukázka Fuzzy segmentace s průměrovou agregací a rozdílnou segmentační třídou, Šum Sůl & Pepř,  $d=0.1$  - Zdroj vlastní**



**Obr. 46 Ukázka Fuzzy segmentace s mediánovou agregací a rozdílnou segmentační třídou, Šum Sůl & Pepř,  $d=0.1$  - Zdroj vlastní**



Obr. 47 Ukázka Fuzzy segmentace s průměrovou agregací a rozdílnou segmentační třídou, Šum Spekle,  $\sigma^2 = 0.8$  - Zdroj vlastní



Obr. 48 Ukázka Fuzzy segmentace s mediánovou agregací a rozdílnou segmentační třídou, Šum Spekle,  $\sigma^2 = 0.8$  - Zdroj vlastní

## 5 Kvantitativní komparace a testování segmentačních metod

Po provedení výše zmíněných úprav se snímky a aplikaci segmentačních metod jsem provedl hloubkovou analýzu účinnosti a výpočetní náročnosti těchto metod. V následující části jsou uvedeny některé tabulky shrnující výsledky provedených analýz. Pro ukázkou jsou v každé podkapitole uvedeny ukázkové grafy z vybraných datových souborů. Veškeré výsledky a grafy vycházející z této práce jsou uvedeny v přílohách této práce.

Obecně se v hlavičce tabulek vyskytuje název a typ provedené segmentace a typ šumu. V levé části tabulky je uvedený parametr popisující šumovou složku obrazových dat. V případě Gaussovského a Spekle šumu se jedná o rozptyl  $\sigma^2$ . U šumu Sůl & Pepř se jedná o hodnotu hostoty  $d$ . Obsah tabulek jsou hodnoty popisující zkoumané evaluační parametry v závislosti na použitém šumu a typu segmentační metody.

Veškeré grafy a tabulky z této práce jsou uvedeny v přílohách, a to pro každou provedenou segmentaci zvlášť a bez srovnání s ostatními výsledky.

### 5.1 Analýza výpočetní náročnosti segmentačních metod

Jedním z evaluačních parametrů segmentačních metod je také výpočetní čas segmentačních algoritmů. Byť, jak se říká, čas je relativní, nikoho nepřekvapí, že v lékařství je čas velmi vzácná veličina. Samozřejmě při detekci patologických útvarů nezáleží, jestli segmentační metoda bude trvat pár minut či hodinu, ale pro zdravotnický personál se jedná o důležitou informaci.

V následující tabulce jsou uvedeny výpočetní časy pro dané segmentační metody s ohledem na zvolený počet segmentačních úrovní.

**Tab. 2 Výpočetní náročnost segmentačních metod v závislosti na počtu segmentačních tříd a zvolené agregační metodě v případě Fuzzy metody**

Segmentační metoda	Počet segmentačních tříd	3	5	10
		Časová náročnost / 30 snímků		
OTSU		2,7 s	6 s	8 s
FUZZY – mediánová agregace		19 min	40 min	70 min
FUZZY – průměrová agregace		21 min	44 min	81 min

Z Tab. 2 vyplývá, že výpočetní náročnost testovaných segmentačních metod je velmi nepoměrná. V tabulce nejsou uvedeny výpočetní hodnoty použitých agregačních typů, neboť jejich výpočetní odlišnost se pohybovala v řádech jednotek vteřin. Hodnoty výpočetních časů jsou zahrnuty do konečného hodnocení segmentačních metod. V tabulce jsou zeleně vyznačeny nejrychlejší výpočetní časy pro daný počet segmentačních tříd. Dle stejného kritéria jsou červeně naopak zvýrazněny časově nejnáročnější segmentační metody.

### 5.2 Výsledky provedené analýzy

Níže uvedené výsledkové tabulky a grafy popisují nejvýraznější dosažené výsledky pro danou zkoumanou analýzu. Veškeré dosažené výsledky z provedené analýzy jsou součástí příloh z důvodu výrazného přesahu obsahu této diplomové práce.

### 5.2.1 Analýza vybraných výsledků segmentace


Účinnost Otsu segmentační metody pro tři segmentační úrovně a Gaussovský šum je zobrazena Tab. 3 a pro Fuzzy prahovací metodu pro průměrovou agregaci a totéž nastavení v Tab. 4 a pro mediánovou agregaci v Tab. 5.

Čeho si lze z výsledné tabulky pro Otsu metodu všimnout jsou průměrné hodnoty korelace, MSE a také PSNR se pohybují na velmi podobných hodnotách. Hodnoty korelačního koeficientu se liší v řádu desetiny bodu, tedy kolem 1%. Takřka zanedbatelných rozdílů také dosahují průměrné hodnoty MSE a PSNR.

**Tab. 3 Shrnutí výsledků Otsu segmentace pro 3 segmenty, Gaussovský šum**

<b>Otsu metoda – 3 segmenty</b>						
<b>Gaussovský šum, <math>\mu = 0,01</math>,</b>						
<b>Rozptyl <math>\sigma^2</math></b>	<b>PSNR–CT snímky</b>	<b>PSNR–MRI snímky</b>	<b>MSE–CT snímky</b>	<b>MSE–MRI snímky</b>	<b>COR– CT snímky</b>	<b>COR– MRI snímky</b>
<b>0,01</b>	8,8627	7,6020	0,1438	0,1750	0,7989	0,7730
<b>0,02</b>	8,6388	7,4844	0,1504	0,1792	0,7548	0,7297
<b>0,03</b>	8,4272	7,4144	0,1574	0,1816	0,7502	0,7284
<b>0,04</b>	8,0735	7,3115	0,1694	0,1853	0,7448	0,7263
<b>0,05</b>	7,8372	7,1950	0,1785	0,1900	0,7403	0,7239
<b>0,06</b>	7,6274	7,1056	0,1870	0,1934	0,7369	0,7218
<b>0,07</b>	7,3945	7,0087	0,1968	0,1976	0,7328	0,7197
<b>0,08</b>	7,2418	6,8806	0,2036	0,2035	0,7294	0,7168
<b>0,09</b>	6,9545	6,8092	0,2171	0,2066	0,7222	0,7149
<b>0,1</b>	6,5483	6,7363	0,2374	0,2097	0,7195	0,7138
<b>0,11</b>	6,3982	6,6499	0,2461	0,2138	0,7163	0,7119
<b>0,12</b>	5,9409	6,5840	0,2714	0,2171	0,7086	0,7101
<b>0,13</b>	5,6836	6,5062	0,2884	0,2211	0,7046	0,7085
<b>0,14</b>	5,4903	6,4453	0,3016	0,2242	0,7016	0,7073
<b>0,15</b>	5,1506	6,3940	0,3218	0,2266	0,6980	0,7062
<b>0,16</b>	5,0430	6,3296	0,3288	0,2301	0,6927	0,7046
<b>0,17</b>	4,8434	6,2795	0,3395	0,2326	0,6909	0,7038
<b>0,18</b>	4,7676	6,2325	0,3453	0,2353	0,6896	0,7029
<b>0,19</b>	4,7178	6,1875	0,3494	0,2376	0,6880	0,7019
<b>0,20</b>	4,6540	6,1444	0,3541	0,2399	0,6876	0,7013
<b>0,21</b>	4,6114	6,1130	0,3574	0,2415	0,6865	0,7008
<b>0,22</b>	4,5510	6,0820	0,3622	0,2432	0,6864	0,7003
<b>0,23</b>	4,4963	6,0248	0,3664	0,2463	0,6854	0,6994
<b>0,24</b>	4,4722	5,9730	0,3684	0,2493	0,6852	0,6984
<b>0,25</b>	4,4206	5,9589	0,3726	0,2502	0,6841	0,6984
<b>0,26</b>	4,3705	5,9105	0,3768	0,2529	0,6839	0,6975
<b>0,27</b>	4,3506	5,8554	0,3787	0,2562	0,6841	0,6968
<b>0,28</b>	4,2929	5,8160	0,3831	0,2585	0,6829	0,6963
<b>0,29</b>	4,2627	5,7608	0,3855	0,2617	0,6830	0,6957
<b>0,30</b>	4,1991	5,7147	0,3909	0,2644	0,6826	0,6950
<b>Statistika evaluačních parametrů</b>						
<b>Medián</b>	<b>5,0968</b>	<b>6,3296</b>	<b>0,3218</b>	<b>0,2284</b>	<b>0,6954</b>	<b>0,7046</b>
<b>Průměr</b>	<b>5,8107</b>	<b>6,4837</b>	<b>0,2910</b>	<b>0,2241</b>	<b>0,7084</b>	<b>0,7102</b>

Na Obr. 49 je vykreslen průběh korelačního koeficientu, který odpovídá predikci před aplikací segmentace. Korelace s rostoucí šumovou složkou klesá, překvapivější je ale velký rozdíl mezi snímky z MRI a CT při různých intenzitách šumu. Je patrné, že CT snímky dosahují lepší korelace při nižších úrovních šumu, ale při vyšších hodnotách dosahují lepších výsledků naopak MRI snímky.



**Obr. 49 Porovnání korelace mezi snímky CT a MRI, Otsu metoda se 3 segmenty, šum Gaussovský - Zdroj vlastní**

Jak vyplývá z Tab. 2, výpočetní náročnost Fuzzy metody je velmi vysoká a vzhledem k omezeným možnostem stolních počítačů a notebooků bylo potřebné snížit nároky na testování. Proto bylo přistoupeno ke snížení segmentovaných snímků, ale také ke snížení úrovní aplikovaných šumů.

Oproti Otsu metodě došlo tedy k testování místo na třiceti snímcích na osmi a zašumění obrazu je aplikováno ve stejném rozmezí, jen s vyšším rozestupem mezi jednotlivými intenzitami. V případě Gaussovského šumu se jedná o zvýšení o tři setiny rozptylu.


Při pohledu na Tab. 4, kde se vyskytují výsledky pro průměrovou agregaci, je patrná změna trendu, neboť fuzzy metoda vykazuje lepších výsledků pro snímky z obou zobrazovacích modalit. Např. u korelace bylo zjištěno zlepšení o 22%. Další významný posun v segmentaci se projevil na parametru PSNR, který u CT snímků vzrostl o takřka 10dB. Snímky z MRI, vykazují také zlepšení, ale jen o 6dB. Střední kvadratická chyba doznala menšího zlepšení, které lze vyčíslit v řádech desetin.

**Tab. 4 Shrnutí výsledků Fuzzy segmentace pro 3 segmenty, průměrová agregace, Gaussovský šum**

<b>Fuzzy metoda – 3 segmenty, průměrová agregace</b> <b>Gaussovský šum, <math>\mu = 0,01</math>,</b>						
<b>Rozptyl <math>\sigma^2</math></b>	<b>PSNR-CT snímky</b>	<b>PSNR-MRI snímky</b>	<b>MSE-CT snímky</b>	<b>MSE-MRI snímky</b>	<b>COR- CT snímky</b>	<b>COR- MRI snímky</b>
<b>0,03</b>	16,1572	12,3731	0,0376	0,1172	0,9513	0,9273
<b>0,06</b>	17,0367	12,4987	0,0224	0,1107	0,9544	0,9317
<b>0,09</b>	17,0782	12,6535	0,0223	0,1078	0,9537	0,9336
<b>0,12</b>	16,8574	12,6314	0,0241	0,1075	0,9445	0,9336
<b>0,15</b>	16,6171	12,6059	0,0262	0,1080	0,9346	0,9330
<b>0,18</b>	15,8913	12,5199	0,0466	0,1087	0,9202	0,9323
<b>0,21</b>	15,1117	12,3605	0,0472	0,1103	0,9118	0,9309
<b>0,24</b>	14,8244	12,1582	0,0555	0,1128	0,9042	0,9289
<b>0,27</b>	14,3131	11,9679	0,0612	0,1148	0,8976	0,9274
<b>0,30</b>	13,2046	11,7177	0,0832	0,1178	0,8860	0,9250
<b>Statistika evaluačních parametrů</b>						
<b>Medián</b>	<b>16,0242</b>	<b>12,4359</b>	<b>0,0421</b>	<b>0,1105</b>	<b>0,9274</b>	<b>0,9313</b>
<b>Průměr</b>	<b>15,7092</b>	<b>12,3487</b>	<b>0,0426</b>	<b>0,1116</b>	<b>0,9258</b>	<b>0,9304</b>

Výsledky pro mediánovou agregaci jsou zobrazeny v Tab. 5. Lze pozorovat obdobnou tendenci ve zkvalitnění segmentace, ale průměrová agregace dosahuje kvalitnějších výsledků s výjimkou korelačního koeficientu u CT snímků. Téměř 3% zlepšení oproti průměrové agregaci činí z mediánové agregace kvalitnější proceduru pro CT snímky ve všech zkoumaných parametrech. Obecně lze také tvrdit, že při třech segmentačních třídách dosahuje Fuzzy segmentační metoda mnohem kvalitnějších výsledků než Otsu metoda, což dokazují výše popsané výsledkové tabulky. Průměrná korelace vykreslená na Obr. 50 opět dokládá fakt, že CT snímky dosahují kvalitnější segmentace při nižších intenzitách šumu, kdežto segmentace MRI snímků vykazuje menší rozptyl.






**Obr. 50** Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 3 segmenty, průměrová agregace, šum Gaussovský - Zdroj vlastní

**Tab. 5** Shrnutí výsledků Fuzzy segmentace pro 3 segmenty, mediánová agregace, Gaussovský šum

Fuzzy metoda – 3 segmenty, mediánová agregace						
Gaussovský šum, $\mu = 0,01$ ,						
Rozptyl $\sigma^2$	PSNR-CT snímky	PSNR-MRI snímky	MSE-CT snímky	MSE-MRI snímky	COR- CT snímky	COR- MRI snímky
0,03	14,3645	10,8711	0,0548	0,1315	0,9501	0,9074
0,06	15,1021	10,9679	0,0345	0,1280	0,9571	0,9095
0,09	14,4081	10,9981	0,0612	0,1261	0,9476	0,9103
0,12	14,9383	10,9818	0,0357	0,1255	0,9559	0,9104
0,15	14,8027	10,9305	0,0375	0,1260	0,9546	0,9097
0,18	14,6093	10,8636	0,0394	0,1276	0,9532	0,9089
0,21	14,4524	10,8496	0,0408	0,1274	0,9520	0,9089
0,24	14,0267	10,7629	0,0460	0,1296	0,9484	0,9077
0,27	13,2108	10,6926	0,0784	0,1298	0,9362	0,9074
0,30	13,4244	10,5483	0,0553	0,1322	0,9435	0,9057
Statistika evaluačních parametrů						
Medián	14,4302	10,8673	0,0434	0,1278	0,9510	0,9089
Průměr	14,3339	10,8466	0,0483	0,1284	0,9499	0,9086



**Obr. 51 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 3 segmenty, mediánová agregace, šum Gaussovský - Zdroj vlastní**

**Tab. 6 Shrnutí výsledků Otsu segmentace pro 3 segmenty, šum Sůl & Pepř**


<b>Otsu metoda – 3 segmenty Šum Sůl &amp; Pepř</b>						
<b>Hustota d</b>	<b>PSNR–CT snímky</b>	<b>PSNR–MRI snímky</b>	<b>MSE–CT snímky</b>	<b>MSE–MRI snímky</b>	<b>COR– CT snímky</b>	<b>COR– MRI snímky</b>
<b>0,01</b>	16,7434	20,5338	0,0239	0,0184	0,9658	0,9804
<b>0,02</b>	13,7162	17,4945	0,0471	0,0372	0,9339	0,9605
<b>0,03</b>	11,6708	15,5948	0,0768	0,0606	0,8967	0,9364
<b>0,04</b>	10,4896	14,3976	0,0987	0,0811	0,8678	0,9143
<b>0,05</b>	9,3870	13,4913	0,1286	0,0963	0,8256	0,8965
<b>0,06</b>	8,7408	12,6601	0,1460	0,1153	0,8026	0,8736
<b>0,07</b>	8,1559	12,0961	0,1641	0,1285	0,7798	0,8566
<b>0,08</b>	7,6713	11,6322	0,1814	0,1400	0,7591	0,8424
<b>0,09</b>	7,2247	11,2692	0,1990	0,1502	0,7387	0,8301
<b>0,1</b>	6,8347	10,8665	0,2164	0,1609	0,7198	0,8175
<b>0,11</b>	6,4789	10,5530	0,2333	0,1711	0,7021	0,8061
<b>0,12</b>	6,1293	10,2801	0,2516	0,1801	0,6833	0,7959
<b>0,13</b>	5,8421	9,9958	0,2679	0,1894	0,6676	0,7860
<b>0,14</b>	5,5393	9,7683	0,2863	0,1981	0,6504	0,7767
<b>0,15</b>	5,2725	9,5381	0,3038	0,2069	0,6346	0,7677
<b>0,16</b>	5,0260	9,3051	0,3206	0,2167	0,6200	0,7580
<b>0,17</b>	4,7787	9,1058	0,3388	0,2257	0,6048	0,7494




0,18	4,5187	8,8978	0,3597	0,2346	0,5841	0,7409
0,19	4,3073	8,7328	0,3770	0,2426	0,5706	0,7337
0,20	4,0977	8,5511	0,3950	0,2518	0,5566	0,7256
0,21	3,9170	8,3585	0,4114	0,2605	0,5446	0,7176
0,22	3,7281	8,2006	0,4291	0,2689	0,5318	0,7107
0,23	3,5530	8,0537	0,4464	0,2773	0,5198	0,7037
0,24	3,3862	7,9112	0,4635	0,2861	0,5083	0,6966
0,25	3,2150	7,7474	0,4818	0,2949	0,4960	0,6895
0,26	3,0706	7,6083	0,4977	0,3036	0,4858	0,6827
0,27	2,9173	7,4928	0,5152	0,3116	0,4749	0,6768
0,28	2,7644	7,3444	0,5334	0,3207	0,4636	0,6698
0,29	2,6347	7,2194	0,5492	0,3288	0,4544	0,6638
0,30	2,4941	7,1170	0,5671	0,3362	0,4437	0,6586
<b>Statistika evaluačních parametrů</b>						
<b>Medián</b>	<b>5,1493</b>	<b>9,4216</b>	<b>0,3038</b>	<b>0,2118</b>	<b>0,6200</b>	<b>0,7580</b>
<b>Průměr</b>	<b>6,1435</b>	<b>10,3939</b>	<b>0,3104</b>	<b>0,2031</b>	<b>0,6496</b>	<b>0,7806</b>

Tab. 6 představuje výsledkovou tabulku pro Otsu segmentaci při třech úrovních a šum Sůl & Pepř. Je z ní na první pohled patrné, že Otsu segmentace je mnohem účinnější při nižších hodnotách šumu, ale naopak při vyšších intenzitách dosahuje podstatně horších výsledků. Vysokých hodnot korelace dosahuje metoda při hustotě šumu od 0.01 do 0.1, poté se hodnoty dostávají do podobných hodnot jako u Gaussovského šumu. U vyšších hodnot šumu korelace u CT snímků klesá k velmi nízké úrovni 44 %. Opět se potvrzuje trend, že data z MRI vykazují lepších hodnot korelace, konkrétně o necelých 14 %. Špičkový poměr signál – šum ale doznává významných změn u MRI snímků, kde došlo ke zkvalitnění segmentace o 10 dB. Naopak u snímků z CT nedošlo takřka žádné změně.

Na Obr. 52 lze pozorovat výše zmíněný trend korelace. Při nejnižší hodnotě šumu dosahuje korelace téměř 100 %, nehledě na typ snímku. Při zvýšení hustoty šumu dochází k rapidnímu poklesu, hlavně tedy u CT snímků.



**Obr. 52 Porovnání korelace mezi snímky CT a MRI, Otsu metoda se 3 segmenty, šum Sůl & Pepř - Zdroj vlastní**



**Obr. 53 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 3 segmenty, průměrová agregace, šum Sůl & Pepř - Zdroj vlastní**


Výsledky Fuzzy segmentace snímků znehodnocených šumem Sůl & Pepř jsou uvedeny v Tab. 7 pro průměrovou, resp. v Tab. 8 pro mediánovou agregaci. Lze zde pozorovat trend výrazného zlepšení korelace u CT snímků, který činí nárůst o 19 %, resp. o 29 %. Ke zlepšení došlo také u zbylých evaluačních parametrů. Velice překvapující jsou ale výsledky u průměrové agregace, kde došlo ke zhoršení segmentace u MRI snímků, a to hlavně u korelačního koeficientu a PSNR.

Mediánová agregace se naopak vyznačuje značným zlepšením všech parametrů u obou typů snímků. Lepších výsledků dosahuje u CT snímků.

Z výše popsaných výsledků lze jednoznačně tvrdit, že Fuzzy metoda při aplikaci tří segmentačních úrovní jednoznačně zlepšuje kvalitu segmentace u CT snímků, k mírnému zlepšení také dochází u MRI snímků, ale pouze při použití mediánové filtrace. Z Obr. 52 a Obr. 55 lze jednoznačně vyčíst, jakého zlepšení se dosáhlo při aplikaci Fuzzy segmentační metody.

**Tab. 7 Shrnutí výsledků Fuzzy segmentace pro 3 segmenty, průměrová agregace, šum Sůl & Pepř**


<b>Fuzzy metoda – 3 segmenty, průměrová agregace</b>						
<b>Šum Sůl &amp; Pepř</b>						
<b>Rozptyl <math>\sigma^2</math></b>	<b>PSNR–CT snímky</b>	<b>PSNR–MRI snímky</b>	<b>MSE–CT snímky</b>	<b>MSE–MRI snímky</b>	<b>COR– CT snímky</b>	<b>COR– MRI snímky</b>
<b>0,03</b>	17,6072	14,8401	0,0263	0,0574	0,8614	0,8416
<b>0,06</b>	15,8101	12,6472	0,0238	0,0688	0,8573	0,8294
<b>0,09</b>	14,4887	11,1417	0,0295	0,1069	0,8502	0,8151
<b>0,12</b>	13,2687	10,1866	0,0375	0,1080	0,8401	0,8018
<b>0,15</b>	11,5341	9,3113	0,0610	0,1284	0,8226	0,7871
<b>0,18</b>	10,7797	8,4739	0,0697	0,1442	0,8071	0,7702
<b>0,21</b>	9,9011	7,7713	0,0880	0,1623	0,7895	0,7513
<b>0,24</b>	9,1403	7,1027	0,1028	0,1887	0,7716	0,7305
<b>0,27</b>	8,5848	6,4135	0,1143	0,2318	0,7552	0,7004
<b>0,30</b>	8,1224	5,7071	0,1243	0,2884	0,7366	0,6580
<b>Statistika evaluačních parametrů</b>						
<b>Medián</b>	<b>11.1569</b>	<b>8.8926</b>	<b>0.0401</b>	<b>0.1363</b>	<b>0.8378</b>	<b>0.7787</b>
<b>Průměr</b>	<b>11.9237</b>	<b>9.3595</b>	<b>0.0419</b>	<b>0.1485</b>	<b>0.8361</b>	<b>0.7686</b>



**Obr. 54** Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 3 segmenty, průměrová agregace, šum Sůl & Pepř - Zdroj vlastní

**Tab. 8** Shrnutí výsledků Fuzzy segmentace pro 3 segmenty, mediánová agregace, šum Sůl & Pepř

Fuzzy metoda – 3 segmenty, mediánová agregace Šum Sůl & Pepř						
Rozptyl $\sigma^2$	PSNR-CT snímky	PSNR-MRI snímky	MSE-CT snímky	MSE-MRI snímky	COR- CT snímky	COR- MRI snímky
0,03	20,6879	16,7426	0,0336	0,0784	0,9845	0,9572
0,06	18,8975	14,3294	0,0230	0,0894	0,9830	0,9453
0,09	17,3659	12,6275	0,0284	0,1421	0,9759	0,9298
0,12	15,8869	11,8265	0,0363	0,1208	0,9658	0,9194
0,15	13,8740	10,7359	0,0602	0,1608	0,9479	0,9035
0,18	12,8257	9,8358	0,0720	0,1754	0,9327	0,8880
0,21	11,9575	9,0401	0,0866	0,1928	0,9137	0,8687
0,24	11,0324	8,2990	0,1027	0,2144	0,8928	0,8497
0,27	10,2748	7,5062	0,1169	0,2542	0,8718	0,8234
0,30	9,5676	6,5124	0,1315	0,3343	0,8465	0,7649
Statistika evaluačních parametrů						
Medián	13,3499	10,2858	0,0661	0,1681	0,9403	0,8957
Průměr	14,2370	10,7455	0,0691	0,1763	0,9315	0,8850




**Obr. 55 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 3 segmenty, mediánová agregace, šum Sůl & Pepř - Zdroj vlastní**

Níže uvedená tabulka uvádí výsledky pro Gaussovský šum při segmentaci Otsu metodou a aplikovanými 5 segmentačními úrovněmi. Z Tab. 9 je patrné, že zvýšený počet segmentačních tříd má za následek téměř 10% zlepšení korelace. Naproti tomu došlo ale k výrazné ztrátě u parametru PSNR a také ke zvýšení střední kvadratické chyby. Nutno podotknout, že ač dle evaluačních parametrů vychází lepší výsledky pro MRI snímky, jedná se o velmi malé rozdíly a pro si myslím, že výsledky lze brát jako rovnocenné.

**Tab. 9 Shrnutí výsledků Otsu segmentace pro 5 segment, Gaussovský šum**

<b>Otsu metoda – 5 segmentů</b>						
<b>Gaussovský šum, <math>\mu = 0,01</math>,</b>						
<b>Rozptyl <math>\sigma^2</math></b>	<b>PSNR-CT snímky</b>	<b>PSNR-MRI snímky</b>	<b>MSE-CT snímky</b>	<b>MSE-MRI snímky</b>	<b>COR- CT snímky</b>	<b>COR- MRI snímky</b>
<b>0,01</b>	3,7583	3,4475	0,4437	0,3672	0,8303	0,8193
<b>0,02</b>	3,6346	3,2534	0,4598	0,3845	0,8259	0,8165
<b>0,03</b>	3,2824	2,9067	0,4942	0,4082	0,8215	0,8145
<b>0,04</b>	2,8958	2,7119	0,5471	0,4308	0,8169	0,8098
<b>0,05</b>	2,7471	2,4826	0,5594	0,4555	0,8144	0,8066
<b>0,06</b>	2,4973	2,2599	0,5942	0,4758	0,8100	0,8037
<b>0,07</b>	2,1253	2,0252	0,6559	0,5016	0,8064	0,8021
<b>0,08</b>	2,0218	1,9031	0,6674	0,5225	0,8050	0,8001
<b>0,09</b>	1,5881	1,6082	0,7431	0,5626	0,7987	0,7977
<b>0,1</b>	1,4150	1,4639	0,7874	0,5862	0,7971	0,7956
<b>0,11</b>	1,0560	1,3238	0,8417	0,6061	0,7936	0,7944

0,12	0,8724	1,1432	0,8802	0,6290	0,7912	0,7922
0,13	0,6507	1,1521	0,9231	0,6443	0,7881	0,7918
0,14	0,4399	0,8929	0,9677	0,6768	0,7858	0,7893
0,15	0,4929	0,8318	0,9684	0,6852	0,7853	0,7885
0,16	0,2634	0,6940	1,0161	0,7105	0,7828	0,7877
0,17	0,2565	0,6428	1,0209	0,7190	0,7826	0,7869
0,18	0,1563	0,6393	1,0436	0,7283	0,7822	0,7868
0,19	0,1834	0,4903	1,0276	0,7571	0,7834	0,7860
0,20	0,1038	0,5655	1,0545	0,7400	0,7835	0,7868
0,21	-0,1310	0,6376	1,1000	0,7116	0,7812	0,7873
0,22	-0,1244	0,5532	1,1023	0,7305	0,7814	0,7879
0,23	-0,2773	0,5362	1,1173	0,7375	0,7804	0,7885
0,24	-0,4430	0,2881	1,1628	0,8027	0,7784	0,7850
0,25	-0,6328	0,1305	1,2002	0,8550	0,7764	0,7838
0,26	-0,8210	-0,0990	1,2463	0,9260	0,7739	0,7816
0,27	-1,0209	-0,2494	1,2951	0,9581	0,7722	0,7803
0,28	-1,2487	-0,3561	1,3709	0,9986	0,7680	0,7793
0,29	-1,3269	-0,4050	1,3910	1,0078	0,7675	0,7790
0,30	-1,5189	-0,4017	1,4503	0,9527	0,7651	0,7795
<b>Statistika evaluačních parametrů</b>						
<b>Medián</b>	<b>0,3516</b>	<b>0,6940</b>	<b>0,9922</b>	<b>0,6852</b>	<b>0,7835</b>	<b>0,7885</b>
<b>Průměr</b>	<b>0,7632</b>	<b>1,1024</b>	<b>0,9377</b>	<b>0,6757</b>	<b>0,7910</b>	<b>0,7930</b>




**Obr. 56 Porovnání korelace mezi snímky CT a MRI, Otsu metoda se 3 segmenty, šum Spekle -  
Zdroj vlastní**

Z Obr. 56 je patný výše popsáný trend, ve kterém zmiňuji velkou podobnost CT a MRI snímků. Na snímku jsou linie, které se velmi podobají.

**Tab. 10 Shrnutí výsledků Fuzzy segmentace pro 5 segmentů, průměrová agregace, Gaussovský šum**


Fuzzy metoda – 5 segmentů, průměrová agregace						
Gaussovský šum, $\mu = 0,01$						
Rozptyl $\sigma^2$	PSNR–CT snímky	PSNR–MRI snímky	MSE–CT snímky	MSE–MRI snímky	COR– CT snímky	COR– MRI snímky
0,03	9,0156	6,1184	0,1691	0,3501	0,9415	0,9156
0,06	8,9765	6,1400	0,1712	0,3448	0,9402	0,9169
0,09	8,5839	6,1596	0,1966	0,3423	0,9376	0,9167
0,12	7,1445	6,0248	0,2500	0,3465	0,9296	0,9165
0,15	7,1867	5,7674	0,2318	0,3569	0,9290	0,9133
0,18	6,9996	5,7620	0,2595	0,3551	0,9277	0,9141
0,21	5,9831	5,3686	0,3148	0,3750	0,9238	0,9106
0,24	6,3679	5,1856	0,2980	0,3829	0,9265	0,9087
0,27	5,8816	4,9443	0,3261	0,3928	0,9215	0,9070
0,30	4,6799	5,0953	0,3832	0,3608	0,9214	0,9128
Statistika evaluačních parametrů						
Medián	7,0720	5,7647	0,2547	0,3560	0,9283	0,9137
Průměr	7,0819	5,6566	0,2600	0,3607	0,9299	0,9132



**Obr. 57 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 5 segmentů, průměrová agregace, Gaussovský šum - Zdroj vlastní**

Tab. 11 Shrnutí výsledků Fuzzy segmentace pro 5 segmentů, mediánová agregace, Gaussovský šum

Fuzzy metoda - 5 segmentů, mediánová agregace Gaussovský šum, $\mu = 0,01$						
Rozptyl $\sigma^2$	PSNR-CT snímky	PSNR-MRI snímky	MSE-CT snímky	MSE-MRI snímky	COR-CT snímky	COR-MRI snímky
0,03	9,4237	6,8811	0,1384	0,2754	0,9447	0,9249
0,06	8,8270	6,6423	0,1683	0,2899	0,9391	0,9221
0,09	8,6661	6,5086	0,1825	0,2968	0,9371	0,9201
0,12	7,6555	6,0743	0,2235	0,3196	0,9308	0,9161
0,15	7,9530	5,8885	0,2172	0,3298	0,9317	0,9140
0,18	6,2412	6,0446	0,3033	0,3189	0,9224	0,9173
0,21	6,7122	5,6011	0,2913	0,3430	0,9247	0,9130
0,24	5,4397	5,4507	0,3623	0,3497	0,9192	0,9121
0,27	5,5144	5,2475	0,3401	0,3564	0,9210	0,9114
0,30	5,3175	4,7828	0,3637	0,3955	0,9216	0,9105
Statistika evaluačních parametrů						
Medián	7,1839	5,9665	0,2574	0,3247	0,9278	0,9150
Průměr	7,1750	5,9122	0,2591	0,3275	0,9292	0,9162



Obr. 58 Porovnání korelace mezi snímky CT a MRI, Fuzzy metoda se 5 segmentů, mediánová agregace, šum Sůl & Pepř - Zdroj vlastní

Z dosažených výsledků lze konstatovat, že segmentace pěti segmentačními třídami poskytuje ve všech případech pro Gaussovský šum kvalitnější výsledků. Z výsledkových tabulek pro Fuzzy



segmentační metody vyplývá, že rozdíl mezi jednotlivými agregačními typy není tak výrazný, jako u aplikace tří segmentačních tříd, nicméně stále poskytuje kvalitnější výsledky. U korelace činí rozdíl cca 12 %. Velkého zlepšení dosahuje Fuzzy metoda také u PSNR, konkrétně 6,4 dB.

### 5.2.2 Celková analýza pro tři segmentační třídy

Níže v tabulkách jsou uvedeny veškeré výsledné průměrné hodnoty vycházející z provedené analýzy. Tab. 12 a Tab. 13 ukazují na výsledky, kterých bylo dosaženo při aplikaci všech segmentačních metod při nastavení třech segmentačních tříd na MRI a CT snímky. Z tabulek je patrné, že nejlepších výsledků bylo dosaženo při aplikaci Fuzzy prahovací metody, která byla použita s průměrovým nebo mediánovým agregátem. Lze konstatovat, že Otsu metoda ani v jednom případě při aplikaci tří segmentačních tříd nedosáhla takových kvalitních výsledků, jako již zmiňovaná Fuzzy metoda. Dalším zjištěním je fakt, že lepších výsledků bylo dosahováno při aplikaci na CT snímky.

**Tab. 12 Průměrné hodnoty evaluačních parametrů pro MRI snímky, 3 segmentační třídy**

Průměrné hodnoty pro obrazy z MRI, 3 segmentační třídy				
Typ segmentace	Typ šumu	PSNR	MSE	Korelace
Otsu	Gaussovský	6,4837	0,2241	0,7102
Fuzzy průměrová		12,3487	0,1116	0,9304
Fuzzy mediánová		10,8466	0,1284	0,9086
Otsu	Sůl & Pepř	10,3939	0,2031	0,7806
Fuzzy průměrová		9,6975	0,2142	0,8639
Fuzzy mediánová		10,7455	0,1763	0,8850
Otsu	Spekle	6,4230	0,2502	0,6974
Fuzzy průměrová		7,6403	0,2409	0,8141
Fuzzy mediánová		8,0792	0,2032	0,8275

**Tab. 13 Průměrné hodnoty evaluačních parametrů pro CT snímky, 3 segmentační třídy**

Průměrné hodnoty pro obrazy z CT, 3 segmentační třídy				
Typ segmentace	Typ šumu	PSNR	MSE	Korelace
Otsu	Gaussovský	5,8107	0,2910	0,7084
Fuzzy průměrová		15,7092	0,0426	0,9258
Fuzzy mediánová		14,3339	0,0483	0,9499
Otsu	Sůl & Pepř	6,1435	0,3104	0,6496
Fuzzy průměrová		13,2893	0,0775	0,9223
Fuzzy mediánová		14,2370	0,0691	0,9315
Otsu	Spekle	7,4494	0,2039	0,7318
Fuzzy průměrová		9,4257	0,1510	0,8587
Fuzzy mediánová		9,4878	0,1340	0,8646

### 5.2.3 Celková analýza pro pět segmentačních tříd

Výsledky popisující segmentaci dat za použití pěti segmentačních tříd lze vidět na Tab. 14 resp. Tab. 15. Je zde opět vidět dominance Fuzzy segmentační metody, hlavně tedy v případě korelačního koeficientu, jenž dosahuje v některých případech rozdílu až 15 %. Je zajímavé, že Otsu metoda v parametrech MSE a PSNR dosahuje u šumu Spekle kvalitnějších výsledků než Fuzzy metoda s průměrovou agregací, ale korelační koeficient se v žádném zkoumaném případě nedostal nad korelační hranici Fuzzy metody.

**Tab. 14 Průměrné hodnoty evaluačních parametrů pro MRI snímky, 5 segmentačních tříd**

Průměrné hodnoty pro obrazy z MRI, 5 segmentačních tříd				
Typ segmentace	Typ šumu	PSNR	MSE	Korelace
Otsu	Gaussovský	1,1024	0,6757	0,7930
Fuzzy průměrová		5,6566	0,2600	0,9299
Fuzzy mediánová		5,9122	0,3275	0,9162
Otsu	Sůl & Pepř	4,9666	0,5998	0,7995
Fuzzy průměrová		6,0430	0,4518	0,9096
Fuzzy mediánová		7,7603	0,3173	0,9291
Otsu	Spekle	2,7250	0,6067	0,7492
Fuzzy průměrová		1,6023	0,9615	0,7770
Fuzzy mediánová		4,1536	0,4864	0,8531

**Tab. 15 Průměrné hodnoty evaluačních parametrů pro CT snímky, 5 segmentačních tříd**

Průměrné hodnoty pro obrazy z CT, 5 segmentačních tříd				
Typ segmentace	Typ šumu	PSNR	MSE	Korelace
Otsu	Gaussovský	0,7632	0,9377	0,7910
Fuzzy průměrová		7,0819	0,2600	0,9293
Fuzzy mediánová		7,1750	0,2591	0,9185
Otsu	Sůl & Pepř	5,1268	0,6196	0,7965
Fuzzy průměrová		8,9173	0,1813	0,9441
Fuzzy mediánová		9,6655	0,1518	0,9514
Otsu	Spekle	3,3908	0,5444	0,7691
Fuzzy průměrová		2,9041	0,5992	0,8346
Fuzzy mediánová		4,9258	0,3684	0,8729

### 5.2.4 Celková analýza pro deset segmentačních tříd


V této podkapitole se nacházejí celkové průměrné hodnoty segmentačních metod při aplikaci deseti segmentačních tříd. Při porovnání hodnot PSNR celým spektrem výsledků je jednoznačně patrný trend zhoršování špičkového poměru signál – šum. Na Obr. 59 je vynesena křivka, která popisuje zmíněný trend, a to, že s rostoucím počtem segmentačních tříd klesá hodnota PSNR a tedy v tomto ohledu dochází ke zhoršení efektivity.

**Tab. 16 Průměrné hodnoty evaluačních parametrů pro MRI snímky, 10 segmentačních tříd**


Průměrné hodnoty pro obrazy z MRI, 10 segmentačních tříd				
Typ segmentace	Typ šumu	PSNR	MSE	Korelace
Otsu	Gaussovský	-4,8686	3,8772	0,8272
Fuzzy průměrová		-0,6461	1,3156	0,9251
Fuzzy mediánová		0,3118	1,0741	0,9433
Otsu	Sůl & Pepř	-1,4732	2,8418	0,7510
Fuzzy průměrová		0,9547	1,1842	0,9243
Fuzzy mediánová		4,3448	0,7277	0,9627
Otsu	Spekle	-2,0840	1,9198	0,6813
Fuzzy průměrová		-5,1802	4,0150	0,7880
Fuzzy mediánová		-1,3057	1,6599	0,8830

**Tab. 17 Průměrné hodnoty evaluačních parametrů pro CT snímky, 10 segmentačních tříd**

Průměrné hodnoty pro obrazy z CT, 10 segmentačních tříd				
Typ segmentace	Typ šumu	PSNR	MSE	Korelace
Otsu	Gaussovský	-4,7240	3,8890	0,8311
Fuzzy průměrová		-0,8433	1,3815	0,9288
Fuzzy mediánová		-1,5769	1,6931	0,9272
Otsu	Sůl & Pepř	-6,3529	5,5354	0,5825
Fuzzy průměrová		1,8665	0,8857	0,9467
Fuzzy mediánová		4,2085	0,4831	0,9699
Otsu	Spekle	-1,9376	2,0820	0,7454
Fuzzy průměrová		-3,5389	3,1449	0,8276
Fuzzy mediánová		-1,0804	1,5279	0,8904



**Obr. 59 Vývoj trendu PSNR v závislosti na počtu segmentačních tříd – Otsu metoda - Zdroj vlastní**



**Obr. 60 Vývoj trendu PSNR v závislosti na počtu segmentačních tříd – Fuzzy metoda – Zdroj vlastní**

### 5.3 Vyhodnocení segmentace po aplikaci mediánové filtrace

V dnešní době je zcela běžnou praxí, že dochází k předzpracování obrazových dat. Filtrace obrazu hraje velmi důležitou roli při předzpracování vedoucí k potlačení rušivých složek obrazu. Při filtraci hraje důležitou roli sousední body pixelů. Pro zjištění důležitosti filtrace byl na obrazová data aplikován mediánový filtr a to ve velikosti masky  $5 \times 5$  a  $10 \times 10$ . Pro aplikaci musí dojít k utřídění velikosti všech vektorů v masce. Prostřední bod obrazové matice poté nahrazuje prostřední hodnota seřazených hodnot.

**Tab. 18 Průměrné hodnoty evaluačních parametrů po aplikaci mediánové filtrace pro CT snímky.**

<b>Průměrné hodnoty pro obrazy z CT, Mediánová filtrace</b>				
Typ segmentace	Typ šumu	PSNR	MSE	Korelace
Otsu 3	Gaussovský	<b>8,2229</b>	<b>0,1781</b>	<b>0,7926</b>
Otsu 5		<b>2,8927</b>	<b>0,5782</b>	<b>0,8318</b>
Otsu 10		<b>-3,4219</b>	<b>2,8551</b>	<b>0,8306</b>
Otsu 3	Sůl & Pepř	<b>8,3076</b>	<b>0,1927</b>	<b>0,7450</b>
Otsu 5		<b>3,5222</b>	<b>0,6270</b>	<b>0,7416</b>
Otsu 10		<b>-2,1226</b>	<b>2,9190</b>	<b>0,7220</b>
Otsu 3	Spekle	<b>7,9959</b>	<b>0,1587</b>	<b>0,7666</b>
Otsu 5		<b>3,4121</b>	<b>0,4835</b>	<b>0,7542</b>
Otsu 10		<b>-1,9376</b>	<b>1,8724</b>	<b>0,7408</b>

**Tab. 19 Průměrné hodnoty evaluačních parametrů po aplikaci mediánové filtrace pro MRI snímky.**


<b>Průměrné hodnoty pro obrazy z MRI, Mediánová filtrace</b>				
Typ segmentace	Typ šumu	PSNR	MSE	Korelace
Otsu 3	Gaussovský	2,6623	<b>0,4286</b>	<b>0,8327</b>
Otsu 5		<b>2,8317</b>	<b>0,5591</b>	<b>0,7853</b>
Otsu 10		<b>-0,9208</b>	<b>1,3266</b>	<b>0,7707</b>
Otsu 3	Sůl & Pepř	<b>5,5859</b>	<b>0,4308</b>	<b>0,7796</b>
Otsu 5		<b>3,5266</b>	<b>0,4893</b>	<b>0,7835</b>
Otsu 10		<b>1,5209</b>	<b>0,6962</b>	<b>0,7757</b>
Otsu 3	Spekle	<b>5,1475</b>	<b>0,4383</b>	<b>0,7666</b>
Otsu 5		<b>2,8040</b>	<b>0,5318</b>	<b>0,7612</b>
Otsu 10		<b>0,9400</b>	<b>0,7449</b>	<b>0,7510</b>

V Tab. 18 a Tab. 19 jsou k nahlédnutí zobrazena výsledná data evaluačních parametrů pro snímky, na které byla aplikovaná mediánová filtrace. Tento filtr má za následek jednak zlepšení takřka všech parametrů filtrace, ale také konzistentnost výsledných dat. Např. parametr PSNR u MRI snímků se pohybuje Gaussovského šumu mezi -0,9 – 2,7 dB, kdežto u stejných obrazových dat bez mediánové filtrace je se hodnoty PSNR pohybují v rozmezí -4,9 – 6,5 dB. Na jednu stranu dochází ke zkreslení snímků, a proto dochází ke zhoršení některých parametrů, což se nevypálí u snímků poškozených malou intenzitou šumu. Na stranu druhou, je-li intenzita šumu na vysoké úrovni, mediánová filtrace je nástrojem, kterým lze dosáhnout výrazného zlepšení segmentace.

## 6 Graficko-uživatelské rozhraní

V předchozích kapitolách je shrnut postup segmentačních procedur jejich vyhodnocení účinnosti. Tato kapitola se bude zabývat uživatelské aplikace sloužící k aplikaci segmentace primárně biomedicínských snímků bez nutnosti orientace ve zdrojovém kódu. Vyvinuté uživatelské rozhraní bylo vytvořeno v programu MATLAB.

Graficko-uživatelské rozhraní je složeno ze dvou částí, které jsou navzájem propojeny pomocí volání vytvořených funkcí.



Obr. 61 Blokový diagram GUI - Zdroj vlastní




Obr. 62 Use – case diagram - Zdroj vlastní

Po spuštění aplikace „Regionální segmentace 1.0.0“ se objeví úvodní obrazovka, která obsahuje dva ovládací prvky. Toto okno slouží k výběru segmentační metody. Uživatel má na výběr ze dvou segmentačních procedur, a to buď Otsu segmentaci, která je založena na tvrdém prahování a


Fuzzy segmentaci, která je založena měkkém prahování. Na Obr. 63 je zobrazena úvodní obrazovka vyvinuté aplikace.

Po výběru segmentační metody dojde k automatickému zobrazení vyhledávacího okna, ve kterém si uživatel může vybrat snímek, který chce segmentovat, viz Obr. 64.



**Obr. 63 Úvodní obrazovka segmentační aplikace - Zdroj vlastní**

Jakmile je vybrán snímek, který bude dále segmentován, dojde k načtení hlavního segmentačního okna aplikace. V levé horní části se nachází vykreslovací panel, do kterého je vybraný snímek zobrazen. V prostřední části, pod názvem aplikace „Regionální segmentace 1.0.0“ se nachází několik ovládacích panelů, které slouží k umělému zašumění snímku. Uživatel má na výběr ze tří typů šumu, a to *Gaussian*, *Salt & Pepper* a *Speckle*. K volbě typu šumu slouží výběrové menu s názvem *Šum*. Na Obr. 65 lze vidět segmentační okno po načtení nativního snímku.




**Obr. 64** Dialogové okno s možností výběru snímku - Zdroj vlastní

V sekci *Parametry šumu* se vyskytují prázdná textová okna, do kterých se wpisují parametry zvoleného šumu. V případě Gaussovského šumu se jedná o střední hodnotu ( $\mu$ ), která je v aplikaci reprezentována písmenem „X“ a rozptyl ( $\sigma^2$ ), reprezentován písmenem „Y“. V případě šumu *Salt & Pepper* je k dispozici jedno okno reprezentováno písmenem „X“ a představuje hustotu ( $d$ ). U šumu *Speckle* je také k dispozici okno „X“, které představuje rozptyl ( $\sigma^2$ ).

K aplikaci navoleného šumu slouží ovládací okno s názvem *Aplikovat šum*. Po aplikaci šumové složky do snímku dojde k transformaci již vykresleného nativního snímku do šumem zasaženého snímku. Takto transformovaný snímek je vykreslen na místo nativního.




Změnu segmentačního okna po aplikaci šumové složky lze pozorovat na Obr. 65. Dále se uživateli zpřístupní ovládací okno *Segmentovat*, které slouží k aplikaci segmentace se zvolenými parametry. Ty se nastavují v podobě volby počtu tříd v kolonce *počet segmentačních tříd*. K výběru slouží výběrové okno s předdefinovaným počtem tříd. V případě volby Fuzzy segmentační metody je k dispozici při nastavení parametrů segmentace dostupné také výběrové menu pro volbu typu agregace, což lze vidět na Obr. 67.




**Obr. 65 Segmentační okno po aplikaci šumu - Zdroj vlastní**

Po nastavení všech potřebných parametrů a stisknutí ovládacího okna *Segmentovat* dojde k vyobrazení segmentovaného snímku. Souběžně s vykreslením segmentace dojde také k provedení výpočtu evaluačních parametrů a následnému zapsání do příslušných kolonek v aplikaci. Na Obr. 66 a Obr. 67 je zobrazeno segmentační okno s již provedenou segmentací na zvoleném snímku. Obr. 66 zobrazuje Otsu segmentaci, Obr. 67 Fuzzy segmentaci.



Obr. 66 Graficko - uživatelské rozhraní po provedení Otsu segmentace - Zdroj vlastní



Obr. 67 Graficko – uživatelské rozhraní po provedení Fuzzy segmentace - Zdroj vlastní

## 7 Diskuse

Hlavním cílem této diplomové práce byla hloubková komparativní analýza mezi dvěma segmentačními metodami, konkrétně mezi Otsu, která je založená na tvrdém prahování a Fuzzy metodou, jejíž princip je založen na měkkém prahování. K analýze bylo vybráno několik segmentačních tříd, konkrétně 3, 5 a 10. Pro testování byly vybrány reálné medicínské snímky, které byly vytvořeny pomocí výpočetní tomografie a magnetické rezonance. Vybrané snímky zobrazují oblasti cév, jater a kolenních chrupavek. Snímek, se kterým byly segmentace porovnávány, byl zvolen nativní snímek v monochromatickém tvaru. Pro komparaci bylo nutné vložit do obrazu šumovou složku, k čemuž posloužily šumové generátory pro Gaussovský šum, šum Sůl & Pepř a Spekle šum. Na data byly šumové složky aplikovány pro 30 různých intenzit, aby byla dodržena rostoucí dynamika šumu. K objektivnímu vyhodnocení efektivity segmentačních procesů byly zvoleny tři evaluační parametry, kterými byly parametry MSE, PSNR a korelační koeficient.

Z výsledků rozsáhle analýzy vyplývá, že volba ideální segmentační procedury je závislá na obsaženém šumu v obraze a jeho intenzitě. Dále také vyplývá, že existuje závislost na typu obrazových dat, tedy zda se jedná o snímek z MRI nebo CT, což bylo prokázáno v kapitole 5. Je důležité vzít v potaz, že šum obsažený v obrazových datech může obsahovat důležité informace pro diagnostické účely a proto je důležité provádět segmentaci co nejefektivněji. Z dosažených výsledků vyplývá, že Otsu metoda je vhodnější pro MRI snímky, které obsahují šum Sůl & Pepř a Gaussovský šum, v případě šumu Spekle je vhodnější pro CT snímky. V případě Fuzzy metody bylo dosaženo lepších výsledků u CT snímku s šumem Sůl & Pepř a Spekle. Gaussovský šum vykazoval lepších výsledků u MRI snímků. Při porovnávání účinnosti Fuzzy metody byla také vzata v potaz použitá agregační metoda. Při porovnávání dosáhla lepších výsledků průměrová agregace, která vykazovala lepších výsledků u šumu Sůl & Pepř a Spekle. Mediánová agregace je naopak vhodnější pro Gaussovský šum. Je důležité zmínit, že Fuzzy metoda vykazuje podstatně lepších výsledků, ale její efektivita je vykoupěna výpočetní náročností. Průměrně je Fuzzy metoda až  $450 \times$  výpočetně náročnější než Otsu metoda.

Jelikož výběr ideálního segmentačního aparátu může mít za následek správnou, nebo naopak špatnou diagnostiku, je vhodné a přínosné provádět experimentální analýzy a porovnávat efektivitu jednotlivých segmentačních metod. V této práci lze tedy dále pokračovat např. aplikací šumových generátorů s menším rozestupem jednotlivých intenzit. V praxi se totiž v dnešní době nesetkáváme s tak výrazným šumem v obraze, a tudíž by bylo vhodné snížit maximální hodnoty šumu. Na práci by se také dalo navázat v případě testování většího počtu segmentačních tříd. V této práci byly zvoleny tři úrovně segmentačních tříd se značným rozestupem. Zde by bylo možné aplikovat až 7 tříd a poté by bylo možné porovnávat, jaký počet segmentačních tříd je vhodnější. V neposlední řadě se v práci může pokračovat porovnáváním různých typů agregací u Fuzzy prahovací metody. Existuje několik typů agregací a v této diplomové práci byly použity dvě. Lze tedy tuto práci dále rozšířit o porovnání všech agregačních typů.

## 8 Závěr

Hlavním cílem této diplomové práce byla hloubková komparativní analýza dvou segmentačních metod. Na straně jedné Otsu segmentační metoda, která je založená na tvrdém prahování a na straně druhé Fuzzy soft prahovací metoda. Analýza byla prováděna v závislosti na typu snímku, tedy zda jsou pro segmentaci vhodnější snímky z magnetické rezonance či výpočetní tomografie. Dále byla zkoumána závislost dynamiky šumové složky v obraze v závislosti na počtu segmentačních tříd.

Pro realizaci byla nejprve zapotřebí seznámení se s problematikou segmentace a konkrétně regionální segmentace. Po nasbírání dostatečných znalostí jsem přistoupil k dalšímu kroku, kterým bylo vytvoření databáze klinických dat. Konkrétně byly vytvořeny 4 databáze, ve kterých je dohromady 80 snímků. Databáze byly rozděleny podle původu snímků, a to na CT a MRI snímky.

V další části bylo přistoupeno k aplikaci šumových generátorů, přičemž byly zvoleny 3 odlišné typy. Aditivní Gaussovský šum, multiplikativní Spekle a impulsní Sůl & Pepř. Celkem bylo na každý snímek aplikováno 30 intenzit šumu o rozdílných hodnotách, což bylo provedeno kvůli zkoumání efektivity segmentace v závislosti na dynamicky se měnící šumové složce.

Takto poškozené snímky byly poté použity k objektivnímu posouzení efektivity segmentace, a to za pomoci evaluačních parametrů. Jako porovnávané segmentační metody byly použity již výše zmíněné Otsu segmentační metoda a Fuzzy soft prahovací metoda. Pro každý typ segmentace byly zvoleny 3 rozdílné hodnoty segmentačních tříd. Byla tedy testována segmentace pro 3, 5 a 10 segmentačních tříd. U Fuzzy metody byly navíc testovány typy agregačních aparátů. Zde byly zvoleny průměrová a mediánová agregace.

Z výsledků je patrné, že jednoznačně lepších výsledků dosahuje Fuzzy soft prahovací metoda, která dosahovala lepší korelace až o 22 % u Gaussovského šumu pro 3 segmentační třídy. Jednoznačně lepších výsledků dosahuje také u parametru PSNR, kde dosahuje až od 10 dB většího špičkového poměru signál – šum. Střední kvadratická chyba dosahuje až o 50 % lepších výsledků. V případě segmentace na 5 úrovní mají výsledky obdobný trend. Fuzzy metoda poskytuje lepší výsledky, ale rozdíl mezi Otsu metodou je podstatně nižší. Rozdíl v parametru PSNR činí 7 dB, což je snížení rozdílu o 3 dB. Obdobných rozdílů hodnot bylo dosaženo také u střední kvadratické chyby. Rozdíl v korelaci se snížil na 12 %. Je zajímavé také pozorovat vývojový trend těchto parametrů, neboť v případě PSNR a MSE došlo ke zhoršení v obou popisovaných příkladech, u Fuzzy metody došlo ke zhoršení výraznějším. Naproti tomu v případě korelačního koeficientu, dle dosažených výsledků došlo ke zhoršení u Fuzzy metody o 2 %, ale Otsu metoda vykazuje zlepšení 9 %.

Následně jsem prováděl analýzu účinnosti segmentace v závislosti na typu snímků. Jak je zmíněno výše, obrazové databáze jsou složeny ze snímků z výpočetní tomografie a magnetické rezonance a proto jsem se snažil zjistit, které metoda je vhodnější na daný typ segmentace. Z mých zjištění vyplývá, že použití Otsu segmentační metody je vhodnější na MRI snímcích. Hlavně tedy v případě, kdy byly snímky zašuměny šumem Gaussovským či Sůl & Pepř. U šumu Spekle je zjištění přesně opačné a tedy dosahuje lepších výsledků u CT snímků. V případě Fuzzy segmentační metody jsem došel k zjištění, že je vhodnější při aplikacích na CT snímky, které jsou znehodnoceny šumem Sůl & Pepř a Spekle. V případě zašuměných snímků Gaussovským šumem bylo lepších výsledků dosaženo u MRI snímků. Co se týče typů agregací, výsledné hodnoty kopírovaly průběhy svých hodnot. Obecně lze ale z dosažených výsledků zjistit, že Fuzzy metoda s mediánovou agregací dosahuje lepších výsledků v případě Gaussovského šumu. Fuzzy metoda s průměrovou agregací naopak dosahuje kvalitnějších výsledků u snímků, které jsou zaneseny šumy Sůl & Pepř a Spekle.

Dále jsem prováděl analýzu výpočetní náročnosti daných segmentačních metod. Je důležité zmínit, že ač Otsu metoda nedosahuje takových výsledků jako Fuzzy soft prahovací metoda, její výpočetní náročnost se pohybovala v rozmezí 2 – 10 sekund. Dolní meze bylo dosaženo při

segmentaci na 3 segmentační třídy, naopak horní mez se váže k segmentaci na 10 segmentačních tříd. Naproti tomu Fuzzy segmentační metoda je podstatně výpočetně náročnější. Čas potřebný k provedení segmentace se pohyboval v mezích 19 - 81 minut. Opět platí, že dolní mez je vztažena k třem segmentům a horní mez k deseti. Dále jsem testoval časovou náročnost mezi aplikovanými agregačními typy. Zde jsem došel k závěru, že rozdíl mezi nimi je z pohledu celkového času zanedbatelný.

Součástí této práce je také vyvinutá aplikace Regionální Segmentace 1.0.0, která slouží k aplikaci segmentačních metod na vybraný snímek. Výsledná aplikace tedy uživateli umožňuje výběr mezi segmentačními metodami či výběr libovolného snímku. Uživateli je dále umožněno aplikovat šumovou složku do signálu a nastavit parametry šumu dle vlastního uvážení. Při provádění segmentace si může uživatel sám navolit počet segmentačních tříd a po provedení segmentace ji může vyhodnotit dle evaluačních parametrů, které se vypíší do určených oken v aplikaci.

Tato práce také zahrnuje laboratorní úlohu, která bude sloužit studentům pro přiblížení problematiky regionální segmentace. Zadáni laboratorní úlohy a vzorový protokol jsou součástí přílohy této práce.

V této diplomové práci lze v budoucnu pokračovat navázáním na testování efektivity segmentace a porovnáváním všech typů agregačních metod v případě Fuzzy soft prahovací metody. Dále lze tuto práci v budoucnu rozšířit a aplikaci na větší počet obrazových databází a dále zjišťovat efektivitu v závislosti na typu snímku. Na práci by se také dalo navázat v případě testování širšího počtu segmentačních tříd. V této práci byly zvoleny tři úrovně segmentačních tříd se značným rozestupem, proto by bylo vhodné aplikovat až 7 tříd. Je také možné tyto segmentační procedury aplikovat také na ultrasonografické snímky či snímky očního pozadí z fundus kamery.

## Literatura

- [1] ŠPANĚL, Michal a Vítězslav BERAN. *Obrazové segmentační techniky: Přehled existujících metod*. Brno, 2005. Studijní dokument. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ.
- [2] EL-BAZ, Ayman S, Xiaoyi JIANG a Jasjit S SURJ. *Biomedical image segmentation: advances and trends*. Boca Raton: CRC Press, Taylor & Francis Group, [2017]. ISBN 978-1482258554.
- [3] ZÁVODNÍKOVÁ, Barbora. *Vývoj nástrojů pro segmentaci mozkových komor a tumoru mozku na snímcích za účelem následného vyhodnocení zájmových objektů*. Ostrava, 2018. Diplomová práce. VŠB - technická univerzita Ostrava. Vedoucí práce Prof. Ing. Lačezar Ličev, CSc., prof. h. c.
- [4] GRAU, V., A.U.J. MEWES, M. ALCANIZ, R. KIKINIS a S.K. WARFIELD. *Improved Watershed Transform for Medical Image Segmentation Using Prior Information* [online]. [cit. 2018-10-12]. DOI: 10.1109/TMI.2004.824224. ISBN 0278-0062. Dostupné z: <http://ieeexplore.ieee.org/document/1281998/>
- [5] *The Watershed Transformation* [online]. 2010 [cit. 2014-11-17]. Dostupné z: <http://cmm.enscm.fr/~beucher/wtshed.html>.
- [6] HÁJOVSKÝ, Radovan, Radka PUSTKOVÁ a František KUTÁLEK. *Zpracování obrazu v měřicí a řídicí technice*. Vyd. 1. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 2012, 1 DVD-ROM. ISBN 978-80-248-2596-0.
- [7] MA, Zhen, João Manuel R. S. TAVARES a Jorge NATAL R. M. *A REVIEW ON THE CURRENT SEGMENTATION ALGORITHMS FOR MEDICAL IMAGES*. Porto. A Review. University of Porto,.
- [8] JAN, Jiří. *Medical image processing, reconstruction, and restoration: concepts and methods*. Boca Raton, FL, 2006. ISBN 08-247-5849-8.
- [9] HLAVÁČ, Václav. *Digitální obraz, základní pojmy [přednáška]*. Praha: České vysoké učení technické v Praze, dostupné z: <http://people.ciirc.cvut.cz/~hlavac/TeachPresCz/11DigZprObr/014DigitalImageCz.pdf>.
- [10] KLÁSEK, Pavel. *SEGMENTACE ZÁKLADNÍCH ČÁSTÍ LIDSKÉHO MOZKU V MR DATECH*. Brno, 2012. Bakalářská práce. VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ. Vedoucí práce Ing. MILOŠ MALÍNSKÝ.
- [11] DOUGHERTY, Geoff. *Digital image processing for medical applications*. New York: Cambridge University Press, 2009. ISBN 978-0-521-86085-7.
- [12] VALOŠEK, Jan. *Automatizovaný software pro úpravu a analýzu medicínských snímků*. Ostrava, 2015. Bakalářská práce. VŠB - TU Ostrava. Vedoucí práce Ing. Jan Kubíček.
- [13] STRAKA, Stanislav. *Segmentace obrazu*. Brno, 2009. Diplmová práce. Masarykova univerzita. Vedoucí práce Mgr. Radka Pospíšilová.
- [14] GROS, Jan. *SEGMENTACE OBRAZU ZALOŽENÁ NA RELIÉFU*. Brno, 2013. Bakalářská práce. Vysoké učení technické v Brně. Vedoucí práce Ing. Aleš Křupka.
- [15] JANOUŠKOVÁ, Eva. *STATISTICKÉ METODY SEGMENTACE V MRI OBRAZECH MOZKU*. Brno, 2008. Bakalářská práce. Masarykova univerzita. Vedoucí práce Ing. Daniel Schwarz, Ph.D.

- [16] SOJKA, Eduard. *Digitální zpracování a analýza obrazů*. Ostrava: VŠB-Technická univerzita, 2000. ISBN 80-7078-746-5
- [17] DRAHORÁDOVÁ, Lucie. *Vývoj nástrojů pro segmentace a volumetrie mozku u RS - roztroušené sklerózy za účelem následného vyhodnocení zájmových objektů*. Ostrava, 2018. Diplomová práce. VŠB - TU Ostrava. Vedoucí práce Prof. Ing. Lačezar Ličev, CSc., prof.h.c.
- [18] NASOR, Mohamed a Walid OBAID. *MRI Tumor Detection and Localization by Multiple Threshold Object Counting Technique*. 2018 International Conference on Computer and Applications (ICCA) [online]. IEEE, 2018, 2018, , 158-161 [cit. 2018-11-08]. DOI: 10.1109/COMAPP.2018.8460322. ISBN 978-1-5386-4371-6. Dostupné z: <https://ieeexplore.ieee.org/document/8460322/>
- [19] MIKEL, Martin. *Vývoj nástroje zpracování obrazu pro vyčítání registračních značek silničních vozidel*. Zlín, 2017. Diplomová práce. Univerzita Tomáše Bati ve Zlíně. Vedoucí práce Ing. Jiří Ševčík.
- [20] QU, Zhong a Li ZHANG. *Research on Image Segmentation Based on the Improved Otsu Algorithm*. 2010 Second International Conference on Intelligent Human-Machine Systems and Cybernetics [online]. IEEE, 2010, 2010, , 228-231 [cit. 2018-11-11]. DOI: 10.1109/IHMSC.2010.157. ISBN 978-1-4244-7869-9. Dostupné z: <http://ieeexplore.ieee.org/document/5590856/>
- [21] ZHU, Ningbo, Gang WANG, Gaobo YANG a Weiming DAI. *A Fast 2D Otsu Thresholding Algorithm Based on Improved Histogram*. 2009 Chinese Conference on Pattern Recognition [online]. IEEE, 2009, 2009, , 1-5 [cit. 2018-11-11]. DOI: 10.1109/CCPR.2009.5344078. ISBN 978-1-4244-4199-0. Dostupné z: <http://ieeexplore.ieee.org/document/5344078/>
- [22] Hetal J. Vala and Astha Baxi, "A Review on Otsu segmentation algorithm", *IJAR CET Vol 2, Issue 2, Únor 2013*
- [23] Khushbu a Isha VATS. *Otsu Image Segmentation Algorithm: A Review*. International Journal of Innovative Research in Computer and Communication Engineering: Vol. 5, Issue 6, June 2017. *IJIR CCE*, 2017, 11945 - 11948 [cit. 2018-11-11]. Dostupné z: [http://www.ijircce.com/upload/2017/june/164\\_21\\_Otsu.pdf](http://www.ijircce.com/upload/2017/june/164_21_Otsu.pdf)
- [24] LIČEV, Lačezar. *Systém FOTOMng: architektura, funkce a použití*. Praha: BEN - technická literatura, 2015. ISBN 978-80-7300-521-4.
- [25] KAUSHIK, Saurav. *An Introduction to Clustering and different methods of clustering*. In: *Analytics Vidhya* [online]. 2016, 2016 [cit. 2018-11-14]. Dostupné z: <https://www.analyticsvidhya.com/blog/2016/11/an-introduction-to-clustering-and-different-methods-of-clustering/>
- [26] LEI, Li a Yuemei REN. *Medical Image Segmentation Based on Modified Ant Colony Algorithm with GVF Snake Model*. International Seminar on Future BioMedical Information Engineering [online]. China: Department of Computer Engineering Henan Polytechnic Institute, 2008, 2008 [cit. 2018-11-14]. Dostupné z: <https://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=5076672>
- [27] PASÁČEK, Václav. *Segmentace obrazu podle textury* [online]. *Vysoké učení technické v Brně. Fakulta informačních technologií*, 2012 [cit. 2018-11-19]. Dostupné z: <http://hdl.handle.net/11012/53606>. Diplomová práce. Vysoké učení technické v Brně. Fakulta

- informačních technologií. Ústav počítačové grafiky a multimédií. Vedoucí práce Ing. Michal Španěl, Ph.D.
- [28] PEJZNOCH, Aleš. Fuzzy prahování. Brno, 2011. Bakalářská práce. Masarykova univerzita. Vedoucí práce RNDr. Martin Maška, Ph.D.
- [29] Alsabti, S., Khaled; Ranka; Singh, V.: An efficient k-means clustering algorithm. Electrical Engineering and Computer Science. Paper 43., 2009.
- [30] STANĚK, Stanislav. Hierarchické metody segmentace obrazu. Brno, 2008. Bakalářská práce. Vysoké učení technické v Brně. Vedoucí práce Ing. Michal Španěl.
- [31] MAZANEC, Jiří. Program pro prohlížení a segmentaci 3D MRI dat. Praha, 2008. Diplomová práce. České vysoké učení technické v Praze. Vedoucí práce Dr. Ing. Jan Kybic.
- [32] Smith, Lindsay. I. (2002). A tutorial on Principal Components Analysis (Computer Science Technical Report No. OUCS-2002-12). Dostupné z <http://hdl.handle.net/10523/7534>
- [33] DIRK, Jan Kroon. Active Shape Model (ASM) and Active Appearance Model (AAM). MathWorks [online]. MathWorks, 2012 [cit. 2018-11-21]. Dostupné z: <https://www.mathworks.com/matlabcentral/fileexchange/26706-active-shape-model-asm-and-active-appearance-model-aam>
- [34] VONDRÁK, Ivo. Umělá inteligence a neuronové sítě. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava, 1998. ISBN 80-707-8259-5.
- [35] SKOPAL, Tomáš. Neuronové sítě a Information Retrieval. 1. Ostrava: Vysoká škola báňská - Technická univerzita Ostrava. Dostupné z: <http://www.cs.vsb.cz/arg/techreports/neural.pdf>
- [36] AHIRWAR, Anamika. Study of Techniques used for Medical Image Segmentation and Computation of Statistical Test for Region Classification of Brain MRI. International Journal of Information Technology and Computer Science [online]. 2013, 5(5), 44-53 [cit. 2018-11-27]. DOI: 10.5815/ijitcs.2013.05.06. ISSN 20749007. Dostupné z: <http://www.mecspress.org/ijitcs/ijitcs-v5-n5/v5n5-6.html>
- [37] ELAYARAJA, P. a M. SUGANTHI. Survey on Medical Image Segmentation Algorithms. IJARCCCE [online]. 2014, 8591-8593 [cit. 2018-11-27]. DOI: 10.17148/IJARCCCE.2014.31153. ISSN 22781021. Dostupné z: [http://ijarccce.com/upload/2014/november/IJARCCCE4H s nally Survey on Medical Image Segmentation Algorithms.pdf](http://ijarccce.com/upload/2014/november/IJARCCCE4H%20Survey%20on%20Medical%20Image%20Segmentation%20Algorithms.pdf)
- [38] PHAM, Dzung L., Chenyang XU a Jerry L. PRINCE. Current Methods in Medical Image Segmentation. Annual Review of Biomedical Engineering [online]. 2000, 2(1), 315-337 [cit. 2018-11-27]. DOI: 10.1146/annurev.bioeng.2.1.315. ISSN 1523-9829. Dostupné z: <http://www.annualreviews.org/doi/10.1146/annurev.bioeng.2.1.315>
- [39] NG, H.P., S.H. ONG, K.W.C. FOONG, P.S. GOH a W.L. NOWINSKI. Medical Image Segmentation Using K-Means Clustering and Improved Watershed Algorithm. 2006 IEEE Southwest Symposium on Image Analysis and Interpretation [online]. IEEE, 2006, , 61-65 [cit. 2018-11-29]. DOI: 10.1109/SSIAI.2006.1633722. ISBN 1-4244-0069-4. Dostupné z: <http://ieeexplore.ieee.org/document/1633722/>
- [40] NAVEEN, A. a T. VELMURUGAN. Identification of Calcification in MRI Brain Images by k-Means Algorithm. Indian Journal of Science and Technology [online].



- 2015, 8(29) [cit. 2018-11-29]. DOI: 10.17485/ijst/2015/v8i29/83379. ISSN 0974-5645. Dostupné z: <http://www.indjst.org/index.php/indjst/article/view/83379>
- [41] DESPOTOVIĆ, Ivana, Bart GOOSSENS a Wilfried PHILIPS. MRI Segmentation of the Human Brain: Challenges, Methods, and Applications. *Computational and Mathematical Methods in Medicine* [online]. 2015, 2015, 1-23 [cit. 2018-11-30]. DOI: 10.1155/2015/450341. ISSN 1748-670X. Dostupné z: <http://www.hindawi.com/journals/cmmm/2015/450341/>
- [42] Bindu, C.H., Qiscet, O.: An improved medical image segmentation algorithm using OTSU method. *Int. J. Recent Trends Eng.* 2, 88–90 (2009). Dostupné z: [https://www.researchgate.net/publication/229048987\\_An\\_improved\\_medical\\_image\\_segmentation\\_algorithm\\_using\\_OTSU\\_Method/citations](https://www.researchgate.net/publication/229048987_An_improved_medical_image_segmentation_algorithm_using_OTSU_Method/citations)
- [43] GREENSTED, Andrew. Otsu Thresholding. *The Lab Book Pages* [online]. Velká Británie, 2010, 2010 [cit. 2019-04-14]. Dostupné z: <http://www.labbookpages.co.uk/software/imgProc/otsuThreshold.html>
- [44] KUBÍČEK, Jan. Modeling and extraction of the articular cartilage. Ostrava, 2017. Disertační práce. VŠB – Technická univerzita Ostrava. Vedoucí práce Doc. Marek Penhaker.
- [45] GONZALEZ, Rafael C., Richard E. WOODS a Steven L. EDDINS. *Digital Image processing using MATLAB*. 2nd ed. S.I.: Gatesmark Pub., c2009. ISBN 978-0-9820854-0-0.
- [46] HOLUB, Zbyněk. REDUKCE ŠUMU U NÍZKODÁVKOVÝCH CT SNÍMKŮ. Brno, 2015. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Ing. Jiří Chmelík.
- [47] ROUSEK, Marek. Objektivní hodnocení kvality obrazu mluvího znakového jazyka. Praha, 2016. Bakalářská práce. České vysoké učení technické v Praze, Fakulta elektrotechnická, Katedra radioelektroniky. Vedoucí práce Ing. Martin Bernas, CSc.
- [48] Pearson Correlations – Quick Introduction. *SPSS TUTORIALS* [online]. 2018, 2018 [cit. 2019-04-21]. Dostupné z: <https://www.spss-tutorials.com/pearson-correlation-coefficient/>

## A Seznam příloh

Součástí této diplomové práce je také přiložené DVD, které obsahuje ukázkou použitých dat z klinického pracoviště. Dále se na DVD nachází použité funkce a algoritmy.

### Obsah DVD

- **Laboratorní úloha**

Součástí složky „Laboratorní úloha“ jsou dva .pdf soubory, přičemž jeden slouží jako zadání laboratorní úlohy a druhý představuje ukázkový protokol z této úlohy

- Laboratorní úloha – Regionální segmentace.pdf
- Vypracovaný protokol laboratorní úlohy.pdf

- **Kódy a algoritmy**

V této složce se nachází veškeré kódy použité v této diplomové práci. Jedná se hlavně o aplikace šumových generátorů, aplikace segmentace a ukládání evaluačních parametrů. Zdrojové kódy rovněž obsahují stručný popis a význam algoritmů. Dále je součástí této složky *Aplikace Regionální segmentace*, ve které se nachází zdrojový kód k vyvinuté aplikaci. Součástí je také soubor *PopisAplikace.pdf*, které popisuje z jakých částí je aplikace složena.

- Aplikace Regionální segmentace
- Otsu metoda
- Fuzzy metoda

- **Obrazová data**

Složka obrazová data obsahuje ukázkou použitých snímků, které byly testovány v této diplomové práci

- CT – cévy
- CT – játra
- MRI – cévy
- MRI – chrupavky

- **Data**

V této složce se nachází veškeré výsledky evaluačních parametrů pro segmentovaná data. V níže uvedených souborech se dále nachází soubor „*Data\_Hlavička.pdf*“, který popisuje jednotlivé soubory.

- Fuzzy segmentace
- Otsu segmentace

- **Doplňující tabulky**

V této složce se nachází veškeré výsledky evaluačních parametrů pro segmentovaná data v přehledných tabulkách.

- Tabulky.pdf

- **Diplomová práce**

Součástí DVD je uložená textová část diplomové práce ve formátu PDF/A nazvaná *BED0058\_Diplomová práce.pdf*